

Universidad de Córdoba

Programa: *Ingeniería agraria, alimentaria, forestal y de desarrollo rural sostenible*

Línea de investigación: *Protección vegetal*

Estructura y estabilidad de la producción agrícola ante las perturbaciones del cambio climático

Para optar al título de Doctora por la Universidad de Córdoba

Tesis doctoral presentada por:
Rosana Claudia Ferrero Romero

Dirigida por:
Dr. José Luis González Andújar
Dr. Mauricio Lima Arce

Tutor de la Tesis:
Dra. María Jesús Aguilera Ureña

26 de febrero de 2018

Córdoba - España
2018

TITULO: *Estructura y estabilidad de la producción agrícola ante las perturbaciones del cambio climático*

AUTOR: *Rosana Claudia Ferrero Romero*

© Edita: UCOPress. 2018
Campus de Rabanales
Ctra. Nacional IV, Km. 396 A
14071 Córdoba

<https://www.uco.es/ucopress/index.php/es/>
ucopress@uco.es



TÍTULO DE LA TESIS: Estructura y estabilidad de la producción agrícola ante las perturbaciones del cambio climático

DOCTORANDO/A: ROSANA CLAUDIA FERRERO ROMERO

INFORME RAZONADO DEL/DE LOS DIRECTOR/ES DE LA TESIS

(se hará mención a la evolución y desarrollo de la tesis, así como a trabajos y publicaciones derivados de la misma).

El Dr. D. José Luis González Andújar, Investigador Científico del Departamento de Protección de Cultivos del Instituto de Agricultura Sostenible (CSIC), y el Dr. D. Mauricio Lima Arce, Profesor del Departamento de Ecología, Pontificia Universidad Católica de Chile.

Informan

Que el trabajo titulado “*Estructura y estabilidad de la producción agrícola ante las perturbaciones del cambio climático*” ha sido realizado, bajo nuestra supervisión, por la D^a. Rosana Ferrero Romero, y consideramos que reúne los méritos para optar al grado de Doctor.

El propósito de la tesis es lograr una comprensión más profunda y realista sobre los procesos agroecológicos que determinan la dinámica del rendimiento de los cultivos para hacer frente a los impactos del cambio climático. Para ello se propone una aproximación novedosa basada en la teoría de sistemas dinámicos que permite evaluar separadamente distintos tipos de factores (regulación interna poblacional, malas hierbas y climáticos) que pueden determinar la dinámica del rendimiento del cultivo. La tesis supone una confluencia de conocimientos agronómicos, ecológicos y modelado estadístico que la doctorando ha sabido integrar de forma eficiente. Parte del trabajo ha sido desarrollado con estancias temporales en el Dpto. de Ecología de la Pontificia Universidad Católica de Chile y en colaboración con la Global Change and Photosynthesis Research Unit perteneciente al USDA-Agricultural Research Service

(ARS) (Urbana, USA). Adicionalmente, la doctoranda ha completado su plan de formación con asistencia a seminarios, jornadas y cursos relacionados con la temática de la tesis.

La tesis ha dado lugar a novedosos resultados que han permitido proponer distintas medidas de adaptación y mitigación a medio plazo en situaciones y regiones estratégicas para la seguridad alimentaria. Dichos resultados han sido publicados en revistas de alta calidad científica:

Publicaciones

- **Ferrero, R.,** Lima, M., & Gonzalez-Andujar, J. L. (2018). Crop production structure and stability under climate change in South America. *Annals of Applied Biology* 172: 65-73. (Q1; IF 2,04)
- **Ferrero, R.,** Lima, M., Davis, A. S., & Gonzalez-Andujar, J. L. (2017). Weed Diversity Affects Soybean and Maize Yield in a Long Term Experiment in Michigan, USA. *Frontiers in Plant Science*, 8, 236.doi: 10.3389/fpls.2017.00236. (Q1; IF:4,29)
- **Ferrero, R.,** Lima, M. & Gonzalez-Andujar, J. L. (2015) Impacto del cambio climático y el estrés hídrico en la producción de maíz en España. *Tierras de Castilla y León: Agricultura*, 226: 52-57.
- **Ferrero, R.,** Lima, M., & Gonzalez-Andujar, J. L. (2014). Spatio-temporal dynamics of maize yield water constraints under climate change in Spain. *PloS one*, 9(5), e98220. (Q1; IF: 2,80)

Por todo ello, se autoriza la presentación de la tesis doctoral.

Córdoba, 22 de Febrero de 2018

Firma del/de los director/es

Fdo.: José Luis González Andújar

Fdo. Mauricio Lima Arce

Firma de la tutora

Fdo.: María Jesús Aguilera Ureña



TÍTULO DE LA TESIS: Estructura y estabilidad de la producción agrícola ante las perturbaciones del cambio climático

DOCTORANDO/A: ROSANA CLAUDIA FERRERO ROMERO

ESCRITO RAZONADO DEL RESPONSABLE DE LA LÍNEA DE INVESTIGACIÓN
(Ratificando el informe favorable del director. Sólo cuando el director no pertenezca a la Universidad de Córdoba).

Que el trabajo de investigación titulado **“Estructura y estabilidad de la producción agrícola ante las perturbaciones del cambio climático”**, realizado por la doctoranda Dña. **Rosana Claudia Ferrero Romero** bajo la dirección de los Drs. **José Luis González Andújar** y **Mauricio Lima Arce**, puede ser presentado para su exposición y defensa como Tesis Doctoral en la Universidad de Córdoba y ratifico la consideración favorable emitida por los Directores de la tesis doctoral a tal efecto.

Por todo ello, se autoriza la presentación de la tesis doctoral.

Córdoba, 22 de Febrero de 2018

Firma del responsable de línea de investigación

Fdo.: Antonio Trapero Casas

DEPARTAMENTO DE PROTECCIÓN DE CULTIVOS
SECCIÓN AGROECOLOGÍA DE malezas, IAS-CSIC.

El Dr. José Luis González Andújar, Investigador Científico del IAS-CSIC

HACE CONSTAR:

Que el texto adjunto corresponde a la Tesis Doctoral: **Cambio climático y agricultura de cereales: impactos y adaptación**, de la que es autor la licenciada en Ciencias Biológicas Dña. Rosana Claudia Ferrero Romero.

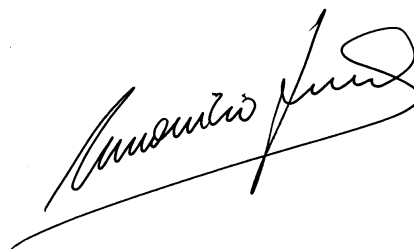
Esta Tesis reúne los requisitos necesarios para su defensa y aprobación para optar al grado de Doctor por la Universidad de Córdoba.

Córdoba, Diciembre de 2017

Vº. Bº. Director de la Tesis



Vº. Bº. Co-director de la Tesis



Dr. José Luis González-Andujar

Dr. Mauricio Lima Arce

Vº. Bº. Tutor de la Tesis



Dra. María Jesús Aguilera Ureña

Artículos publicados:

- Ferrero, R., Lima, M., & Gonzalez-Andujar, J. L. (2018). Crop production structure and stability under climate change in South America. *Annals of Applied Biology* 172: 65-73. (Q1; IF 2,04)
- Ferrero, R., Lima, M., Davis, A. S., & Gonzalez-Andujar, J. L. (2017). Weed Diversity Affects Soybean and Maize Yield in a Long Term Experiment in Michigan, USA. *Frontiers in Plant Science*, 8, 236.doi: 10.3389/fpls.2017.00236. (Q; IF:4,29)
- Ferrero, R., Lima, M. & Gonzalez-Andujar, J. L. (2015) Impacto del cambio climático y el estrés hídrico en la producción de maíz en España. *Tierras de Castilla y León: Agricultura*, 226: 52-57.
- Ferrero, R., Lima, M., & Gonzalez-Andujar, J. L. (2014). Spatio-temporal dynamics of maize yield water constraints under climate change in Spain. *PloS one*, 9(5), e98220. (Q1; IF: 2,80)

Contenidos

Dedicatoria	6
Agradecimientos	7
Resumen	8
1. Introducción	10
1.1 Seguridad alimentaria, sostenibilidad ambiental y cambio climático	10
1.2 Factores que afectan al rendimiento de los cultivos	12
1.2.1 Factores internos (biofísicos) del cultivo	15
1.2.2 Factores externos (climáticos y bióticos) al cultivo	20
1.3 Modelos estadísticos para comprender y predecir el rendimiento de los cultivos	38
1.4 Objetivos	43
2. Cambio climático y agricultura de cereales en el sur de Sudamérica: impactos y adaptación	47
2.1 Introducción	49
2.2 Crop production structure and stability under climate change in South America	51
3. ¿Cómo afecta el cambio climático a la brecha en el rendimiento del maíz entre cultivos de secano y de regadío?	58
3.1 Introducción	60
3.2 Spatio-Temporal Dynamics of Maize Yield Water Constraints under Climate Change in Spain	62
4. Interferencia malezas-cultivo	70
4.1 Introducción	72
4.2 Weed Diversity Affects Soybean and Maize Yield in a Long Term Experiment in Michigan, USA	74
5. Discusión general	82
6. Conclusiones	95
Referencias	97
Apéndice	106

Dedicatoria

Para Mateo, Sebas, Alicia y Fernando

*“Had population and food increased in the same ratio,
it is probable that man might never have emerged from the savage state”.
Thomas Malthus*

*“Science, invention, and technology have given materials and methods for
increasing food supplies substantially and sometimes spectacularly”
Norman E. Boulag*

*“It is not the strongest of the species that survives,
nor the most intelligent that survives.
It is the one that is most adaptable to change”.
Charles Darwin*

Agradecimientos

Hubiera sido imposible realizar esta tesis sin la ayuda de muchas personas que estuvieron animándome en este camino. Quiero agradecerles sinceramente a todos ellos:

A mi pequeño Mateo que me contagia cada día con su alegría y cariño, haciéndome inmensamente feliz.

A Sebastián, “*mi amor, mi cómplice y todo*”, por confiar en mí más que yo misma, por animarme y enseñarme el valor de celebrar los pequeños triunfos.

A mis padres, Alicia y Fernando, por enseñarme el valor del esfuerzo y dedicación, a salir adelante ante la dificultad, y por ser ejemplo de sensibilidad y asombro ante la naturaleza.

A mis amigas y amigos por compartir momentos inolvidables y por su cariño.

A mis directores de tesis José Luis y Mauricio, por su confianza y paciencia, por apoyarme y cuidarme, por compartir su conocimiento y tiempo. Mauricio me permitió participar de sus clases cuando yo aún era un polizone, motivando mi curiosidad e ilusión por la dinámica poblacional; aquella extraña coincidencia ha marcado mi carrera. A José Luis por su gran ayuda en los temas de los cultivos, nuevo y apasionante para mí, por su cariño casi fraternal, por su humor y disposición constante.

A todos aquellos maestros y mentores con los que tuve la suerte de cruzarme: Matías Arim, Bettina Tassino, Enrique Lessa, Omar Defeo, Fernando Mirza y muchos otros, quienes me han enseñado el placer de aprender.

A Fundación Carolina por otorgarme su beca de Doctorado sin la cual no hubiera podido desarrollar mis estudios en España.

Y a los miembros del tribunal por aceptar ser parte del mismo.

¡Gracias a todos!

Resumen

La agricultura contemporánea se enfrenta al enorme desafío de satisfacer la demanda de alimentos de una creciente población mundial, de manera sostenible y frente a un clima cambiante. Hasta ahora los modelos estadísticos utilizados consideran que el rendimiento del cultivo sigue el comportamiento del clima en el cual se encuentra. Sin embargo, esto no suele concordar con los nuevos hallazgos de estancamiento del rendimiento ni con la biología del cultivo (e.g. limitaciones biofísicas), lo cual indica que otros factores tienen que estar implicados. En esta tesis utilizamos una aproximación novedosa basada en la teoría de sistemas dinámicos para evaluar los distintos tipos de factores (internos y externos) que pueden determinar la dinámica del rendimiento del cultivo bajo el efecto del cambio climático. Analizamos la dinámica del rendimiento de los principales cultivos de cereales en regiones estratégicas y cómo distintas variables climáticas, el nivel de CO₂ atmosférico, el riego y la diversidad de malezas han impactado sobre el cultivo durante su período de crecimiento.

Al incluir las limitaciones biofísicas del cultivo en nuestros modelos hemos detectado que la tasa de crecimiento del rendimiento disminuye cuando nos acercamos a su capacidad máxima. Este resultado nos desvela propiedades de regulación y estabilización del sistema, y nos permite explicar y predecir los estancamientos del rendimiento del cultivo a partir de una interpretación biológica simple e intuitiva. Se trata de un resultado clave que determina la capacidad de respuesta y recuperación del cultivo ante modificaciones de su ambiente. Detectamos además características comunes en las dinámicas de rendimiento de cultivos muy distintos (hemos evaluado cultivos de verano e invierno, plantas C₃ y C₄, cereales y oleaginosas, etc.); todos ellos coinciden en los mecanismos internos que generan el patrón observado (retroalimentaciones negativas de primer orden).

Hemos identificado cómo los factores externos (e.g. el cambio climático, el aumento del nivel de CO₂ atmosférico y la diversidad de malezas) afectan al rendimiento del cultivo. Para ello hemos modelado explícitamente todos los mecanismos por los cuales dichos factores podrían perturbar la dinámica del rendimiento (i.e. modificando su capacidad máxima de aumento, su potencial de rendimiento o incluso afectando la forma de la función de la tasa de crecimiento). Un aspecto novedoso que se desprende de nuestros resultados es el hecho de que los efectos climáticos no aditivos (multiplicativos o no lineales; i.e. cuando la respuesta del cultivo depende de su nivel de rendimiento) son más comunes que los aditivos (i.e. cuando el efecto del clima es independiente del rendimiento

del cultivo). Nuestros resultados indican, por tanto, que los cultivos de alto rendimiento son los más vulnerables al cambio climático. Para estos cultivos un pequeño cambio en el clima puede disminuir drásticamente su rendimiento. Este hallazgo podría explicar por qué los cultivos de alto rendimiento suelen presentar una mayor inestabilidad y cómo se generan los patrones no lineales de respuesta del cultivo que hasta ahora han sido difíciles de explicar y predecir. Se trata de un resultado crucial, ya que ignorar la respuesta diferencial de cultivos de bajo y alto rendimiento conduciría a predicciones imprecisas sobre el impacto del cambio climático.

En tercer lugar, en esta tesis evaluamos de manera explícita la efectividad del riego a la hora de disminuir la brecha del rendimiento de los cultivos y, mediante el análisis de experimentos a largo plazo, determinamos bajo qué circunstancias la diversidad de la comunidad de malezas puede ser beneficiosa para los cultivos y cómo interacciona con el clima. Este es un tema clave ya que la adaptación y mitigación del impacto del cambio climático sobre la agricultura pasa por la mejora de la eficiencia en el uso de los recursos utilizados (e.g. el agua para riego y la diversidad del sistema, entre otros). Avanzamos así soluciones a medio plazo en regiones estratégicas para la seguridad alimentaria.

Capítulo 1

1. Introducción

1.1 Seguridad alimentaria, sostenibilidad ambiental y cambio climático

El desafío: situación mundial de los cultivos

La agricultura contemporánea se enfrenta al enorme **desafío** de alimentar a una **creciente población** mundial de manera **sostenible** y frente a un **clima cambiante** ([Challinor et al. 2014](#)). Se prevé que la producción mundial de los principales cultivos **debe aumentar en al menos un 60% hacia el 2050** para satisfacer la demanda de la población, los cambios en la dieta y el aumento del consumo de biocombustibles ([Godfray et al. 2010](#), [Tilman et al. 2011](#), [FAO et al. 2012](#)). Tendremos que **aumentar el rendimiento de los cultivos** (i.e. la cantidad de alimentos producidos por unidad de área) y garantizar su **estabilidad** sin comprometer nuestros recursos (i.e. nuevas tierras y agua para riego) para asegurar su producción en el futuro ([Gregory & Ingram 2000](#), [Lin & Huybers 2012](#), [Iizumi et al. 2014](#)). Además, debido a que el **cambio climático** puede afectar tanto la oferta como la demanda de alimentos, habrá que evaluar su impacto sobre los sistemas actuales de producción de alimentos y hasta qué punto lo hará en el futuro ([Porter et al. 2014](#)).

La agricultura es posiblemente el sector más afectado por el **cambio climático**, incluso en áreas de alto rendimiento y alta tecnología

agrícola ([Ray et al. 2015](#)). Esto ha provocado que **el efecto del clima y su cambio** sobre la producción de alimentos se convierta en **una de las áreas de mayor preocupación científica** ([Lobell & Field 2007](#)). Sin embargo, hasta ahora los resultados sobre la magnitud, la tasa y el patrón de los impactos del cambio climático en la productividad agrícola **difieren y son difíciles de comparar** ([White et al. 2011](#), [Rötter et al. 2011](#), [Wheeler & von Braun 2013](#), [Rosenzweig et al. 2014](#)). Las estimaciones a menudo se caracterizan por **grandes incertidumbres** las cuales indican que todavía debemos mejorar nuestros modelos para poder anticiparnos y adaptarnos al cambio climático ([Lobell & Burke 2008](#)). La clave para reducir esta incertidumbre parece ser una mejor comprensión de las **contribuciones relativas de los factores individuales** que afectan al rendimiento del cultivo ([Lobell & Burke 2008](#)) y de sus **interacciones**. Para ello, en esta tesis vamos a comentar los principales factores que afectan al rendimiento de los cultivos, los modelos estadísticos utilizados para su estudio, los problemas a los que nos enfrentamos y nuestra propuesta para mejorar la comprensión y predicciones sobre la seguridad alimentaria ante el cambio climático.

En esta tesis pondremos el foco en los **cereales** (trigo, maíz, arroz, avena, girasol, cebada, sorgo) y la **soja**. Estos cultivos son la **principal fuente de calorías humana y del ganado**, y son directa o indirectamente (vía el ganado) la principal **fuentes de proteínas** en la mayoría de las regiones ([Lobell & Gourdji 2012](#)). Por ejemplo, la producción del trigo, el arroz, el maíz, la soja, la cebada y el sorgo representan más del 40% de la superficie mundial de tierras de cultivo, el 55% de las calorías no procedentes de la carne y más del 70% de la alimentación animal ([Lobell & Field 2007](#)).

1.2 Factores que afectan al rendimiento de los cultivos

El **esquema general** que rige todos los modelos estadísticos actuales sobre la producción de alimentos se muestra en la figura 1. Este esquema ha sido propuesto en el último informe del IPCC ([Porter et al. 2014](#)) y señala los **componentes principales de la seguridad alimentaria**. Podemos dividir los componentes en *drivers* o factores externos (climáticos/atmosféricos y no climáticos) y *responses* o la reacción del sistema agrícola (en aspectos productivos o no productivos) al impacto de estos *drivers*. Es decir, hasta ahora los modelos estadísticos que evalúan y predicen la producción de los cultivos ante el cambio climático **asumen implícitamente que el sistema está completamente determinado por factores externos y que los procesos son unidireccionales**. Si esto fuera así la producción (o el rendimiento) del cultivo podría crecer de manera indefinida y su **variabilidad sería ilimitada** ya que seguiría a las fluctuaciones externas del ambiente. Sin embargo, **estos fenómenos rara vez ocurren en los sistemas de cultivos reales** donde lo que solemos observar es un techo de rendimiento (o rendimiento máximo) y la **persistencia** del cultivo en el tiempo. En definitiva, las aproximaciones que se están utilizando para explicar y predecir la producción de alimentos parecen ser, al menos, **incompletas**.

En esta tesis utilizamos la **teoría de sistemas dinámicos** y proponemos **nuevos factores explicativos con sus interacciones** para mejorar nuestra comprensión sobre el comportamiento dinámico del rendimiento de los cultivos. Cualquier **sistema dinámico**, desde un automóvil hasta un cultivo, se compone básicamente de **partes que interactúan** y producen de manera conjunta los **patrones de comportamiento** característicos del sistema ([Forrester 1961](#), [von Bertalanffy 1968](#), [Berryman 2008](#)). Este comportamiento viene determinado por las **reglas de interacción** y la **estructura global** de la red de

interacciones. Si logramos entender las **reglas** que determinan las fluctuaciones del rendimiento del cultivo, podremos predecir su comportamiento en el futuro ([Royama 1992](#)). En definitiva, las herramientas que proponemos permiten abordar las **causas estructurales** fundamentales de los problemas de producción de alimentos. Además, el **enfoque interdisciplinario y sistémico** que proponemos es crucial para enfrentar los problemas cada vez más complejos en este nuevo siglo.

En los sistemas dinámicos (como en el cultivo) cabe esperar la existencia de: 1) **factores externos** (ej. recursos, variables climáticas y ambientales, medidas de manejo del cultivo) que perturban o activan los componentes del sistema, 2) **factores internos** (ej. las limitaciones biofísicas del cultivo para la captación de recursos y conversión en biomasa) y la existencia de 3) **interacciones bidireccionales** entre factores que pueden generar una **retroalimentación** (ej. la intensidad de un factor que afecta a un sistema es modulada por el propio sistema a través de un bucle interno). Según la teoría de sistemas dinámicos, el comportamiento observado de un sistema complejo refleja su **estructura**: las relaciones entre los elementos internos del sistema, y cómo el sistema se relaciona con su entorno, con las fuerzas externas ([Royama 1992](#), [Berryman 2008](#)). Intuitivamente podríamos considerar que existe un componente sistemático, **endógeno o interno** al sistema, que genera las oscilaciones básicas [del sistema](#) (ej. [oscilaciones del rendimiento](#)), mientras que algunos componentes aleatorios **exógenos o externos** son responsables de las fluctuaciones secundarias ([Royama 1992](#)). Los primeros suelen involucrar procesos o mecanismos de **retroalimentación** negativa o positiva, mientras que los segundos pueden ser percibidos como **perturbaciones** de estos procesos.

Los **factores internos** y las **interacciones bidireccionales** entre factores son **ignorados actualmente** en los modelos estadísticos de la producción de alimentos (ver por ejemplo [Porter et al. 2014](#)). Sin embargo, podríamos obtener un **comportamiento complejo** a partir de unas **pocas reglas simples** cuando los bucles de retroalimentación están presentes en el

sistema. Los sistemas se vuelven mucho más interesantes y significativos cuando se consideran estos dos fenómenos que proponemos porque, por ejemplo, nos permiten evaluar si existe un control interno del sistema (i.e. **regulación**), explicar su **estabilidad** y las posibles **respuestas no lineales** ([Royama 1992](#)).

La importancia de la distinción **factores internos / externos** es que, si las fuerzas externas dictaran la dinámica de la producción de alimentos, no habría mucha posibilidad de control y de incrementar la producción del cultivo porque la estructura del sistema no podría hacer frente a condiciones externas desfavorables. Sin embargo, la existencia de factores internos que podrían **regular el sistema**, nos permite conocer mecanismos de atenuación de los impactos del cambio climático sobre la producción de alimentos y así proponer medidas de **adaptación y mitigación**.

Veremos en el siguiente capítulo qué nos hace sospechar de la existencia de estos dos fenómenos, cuál es su relación con los factores ambientales externos y, luego, cómo plasmarlo en un modelo estadístico.

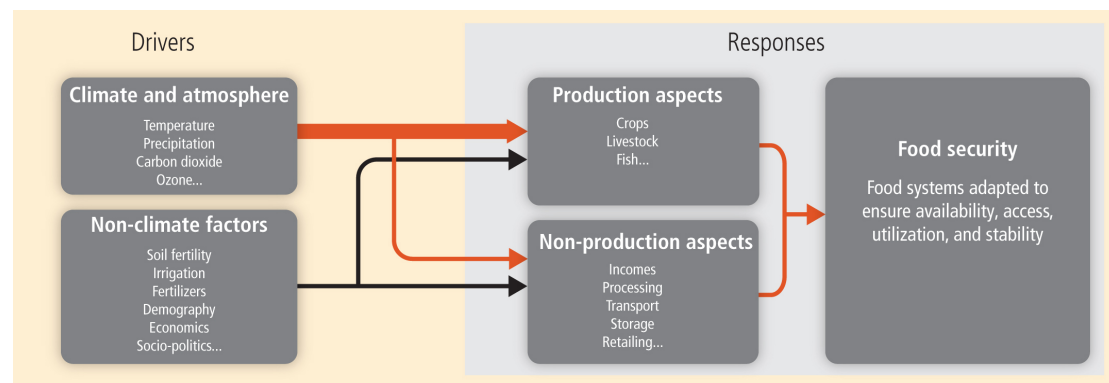


Figura 1. Los principales problemas a resolver para la seguridad alimentaria. Los factores externos climáticos y no climáticos (**drivers**) determinan la respuesta de los sistemas alimentarios (**response**, en aspectos directamente relacionados con la producción o no). El grosor de las líneas rojas es indicativo de la disponibilidad relativa de publicaciones arbitradas en los dos elementos (Figure 7-1; In [Porter et al. 2014](#)).

1.2.1 Factores internos (biofísicos) del cultivo

Limitaciones biofísicas

Históricamente se ha conseguido aumentar el rendimiento de los cultivos mediante el mejoramiento genético y el incremento de los *inputs* (ej. fertilizantes, pesticidas, etc.) y el riego ([Tollenaar 1989](#), [Duvick y Cassman 1999](#), [Khush 1999](#), [Reynolds et al. 1999](#)). Entre 1985 y 2005, la producción total de los principales cultivos mundiales aumentó un 28% (~2,5% mediante una expansión neta de la superficie mundial de los cultivos agrícolas, un aumento del ~7% en la frecuencia de cosecha y un aumento del ~20% en los rendimientos; [Foley et al. 2011](#)). Sin embargo, a partir de los años 90 los rendimientos de los principales cultivos no han aumentado ([Lobell et al 2009](#)) sino que se han estancado o han colapsado en más de una cuarta parte de las tierras de cultivo ([Calderini & Slafer 1998](#), [Finger 2010](#), [Brisson et al. 2010](#), [Ray et al. 2012](#), [Lin & Huyber 2012](#), [Grassini et al 2013](#), [Iizumi et al. 2017](#); Figura 2). Esto ha ocurrido principalmente en las tierras de mayor rendimiento ([Cassman 1999](#)) que representan el 31% de la producción mundial total de estos cereales ([Grassini et al 2013](#)). Por ejemplo, ha ocurrido en el este de Asia para el arroz, o en el noreste de Europa y la India para el trigo, y en el sur de Europa para el caso del maíz ([Grassini et al 2013](#)).

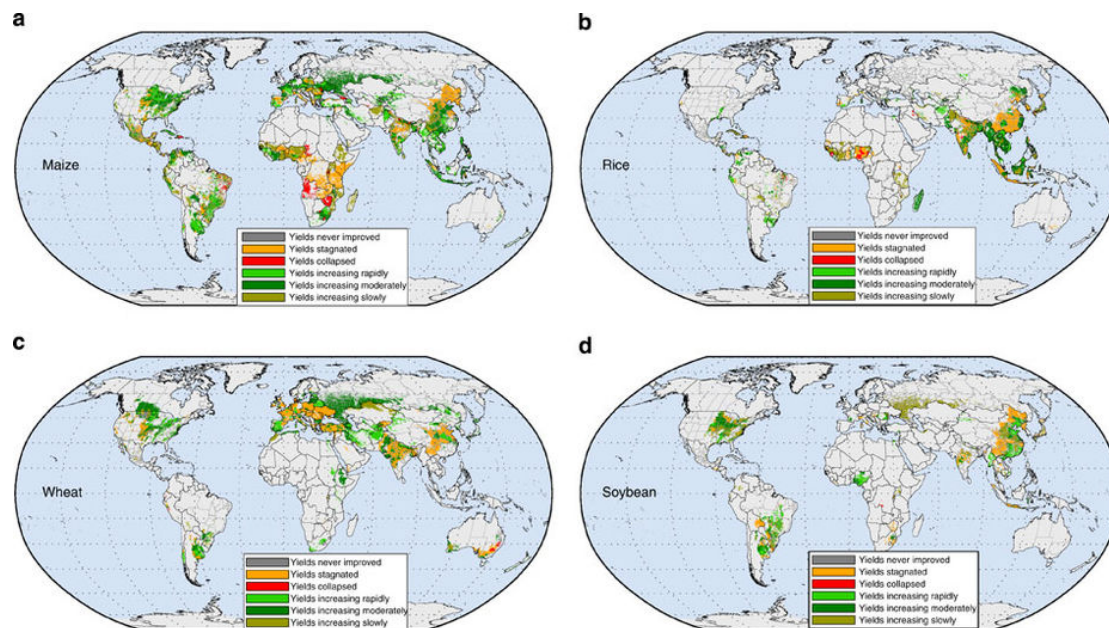


Figura 2. Patrones recientes de crecimiento y estancamiento del rendimiento de los cultivos: a) maíz, b) arroz, c) trigo y d) soja. Se evaluaron los rendimientos de los cultivos para el período 1961-2008 y se determinó el estado de su tendencia de rendimiento actual. Las tendencias se dividieron en las seis categorías que se indican en el código de color. Los mapas solo muestran las áreas de la unidad política donde se cosechó el cultivo. *In* Ray et al. ([2012](#))

Varias hipótesis se han propuesto para dar cuenta de este estancamiento del rendimiento agrícola ([Lobell 2012](#), [Lin & Huybers 2012](#)). Los últimos estudios señalan que se podría deber principalmente a la existencia de **límites biofísicos** sobre el rendimiento de los cultivos ([Grassini et al. 2013](#)), es decir, a los **factores internos** que adelantamos en la sección anterior. Esto implicaría que, una vez que el rendimiento de un cultivo se acercara a su **máximo potencial** resultaría muy difícil aumentar su rendimiento, su **tasa de cambio no sería constante**.

A pesar de la creciente evidencia sobre el estancamiento y colapso del rendimiento de los cultivos, **las proyecciones de la producción**

alimentaria mundial usualmente continúan suponiendo crecimientos constantes ([Evenson 1999](#), [Dyson 1999](#), [Jaggard et al. 2010](#)). Una importante excepción es la investigación reciente de [Izumi et al. \(2017\)](#) que prevé que crecimiento del rendimiento de los cultivos de maíz y soja en los países de altos ingresos ubicados en latitudes medias y altas se estancará, mientras que el del arroz y el trigo no se estancarán. Este trabajo discute cómo podríamos estar generando **predicciones erróneas** sobre la respuesta del cultivo ante el cambio climático si no consideramos posibles problemas de estancamiento de los cultivos. Las medidas de adaptación y mitigación hasta ahora propuestas **podrían no concordar con la capacidad de resiliencia del cultivo ante el cambio climático**. Necesitamos, por tanto, incluir explícitamente en nuestros modelos **tasas de cambio decrecientes con el rendimiento del cultivo**, acorde con los patrones observados y con la biología del cultivo. Esto nos permitirá obtener una **comprensión más profunda de su comportamiento, predicciones más precisas** y proponer **medidas de manejo eficaces**.

Estabilidad

Es necesario un aumento notable en la producción futura de los cultivos para asegurar la alimentación de la población mundial, pero además, **necesitaremos que sea más estable (menos variable)**, ([Calderini & Slafer 1998](#)). Los cambios en la variabilidad interanual de los rendimientos **podrían afectar la disponibilidad y el acceso a los alimentos**. Una expansión de las tierras cultivadas en las zonas más productivas podría teóricamente aumentar la producción mundial, pero también aumentaría su **inestabilidad** si las regiones más productivas se caracterizan por una alta variabilidad interanual del rendimiento como en el caso del maíz estadounidense ([Ben-Ari & Makowski 2016](#)). Esto ocurre en los principales países productores del mundo pero también en regiones con rendimientos comparativamente más bajos, debido a que las fluctuaciones en la producción de cultivos pueden afectar la seguridad alimentaria local ([Ray et](#)

[al. 2015](#)). Además, las regiones con una **alta variabilidad** en el rendimiento de las cosechas pueden contribuir desproporcionadamente al aumento de los **precios de los alimentos** ([Gilbert & Morgan 2010](#), [Lobell et al. 2011](#)).

Aún no existe una explicación clara sobre **cómo afecta el cambio climático a la estabilidad del rendimiento del cultivo**. Los resultados presentados en la literatura sobre la estabilidad del rendimiento de los cultivos suelen ser **contradictorios**. Algunos trabajos indican que la variabilidad interanual de los rendimientos mundiales ha **aumentado** en los últimos años ([Müller et al. 2014](#)), mientras que otros indican que la **disminución** de la variabilidad es la tendencia principal (ej. para el trigo [Calderini & Slafer 1998](#)). Incluso en un mismo estudio encontramos ambos resultados ([Iizumi & Ramankutty 2016](#), Figura 3): durante 1981-2010 disminuyeron las variaciones interanuales del rendimiento del maíz, soja, trigo y arroz en el 19-33% de las áreas cultivadas, mientras que en el otro 9-22% de las zonas cultivadas han aumentado. La estabilidad del rendimiento de los cultivos podría verse afectada por un **cambio en la frecuencia de eventos extremos** a los cuales los cultivos son susceptibles (como las variaciones de la temperatura más allá del rango óptimo; [Iizumi & Ramankutty 2016](#)), o simplemente debido a un **aumento en la variabilidad del clima** como en el caso del maíz en EE.UU. ([Urban et al. 2012](#)). Determinar los mecanismos subyacentes a estos fenómenos y qué cultivos son más susceptibles al aumento de la variabilidad climática, son algunos de los grandes desafíos a los que se enfrenta la agricultura actual.

Asimismo, debemos analizar **qué características del cultivo los vuelven más estables o inestables** para abordar medidas de manejo eficientes. Ben-Ari & Makowski ([2014](#), [2016](#)) señalan que **las zonas de mayor producción suelen ser las más inestables**. Por ejemplo en EE.UU. y Canadá se observa una alta variabilidad interanual y se espera que siga en aumento ([Urban et al. 2012](#)). Este resultado parece indicar, nuevamente, la necesidad de **considerar el nivel del rendimiento del cultivo como factor que condiciona su respuesta al cambio climático**. Sin embargo, hasta

ahora este hallazgo no ha sido incluido explícitamente en los modelos explicativos/predictivos.

Otro punto importante es determinar si el rendimiento del cultivo está **regulado**, lo que implicaría que existen mecanismos internos de **retroalimentación negativa** que **limitan o acotan la variabilidad** del rendimiento a ciertos niveles ([Royama 1977](#), [Berryman 1991](#), [Murdoch 1994](#)). Por el contrario, los **sistemas no regulados -asumidos hasta ahora-** pueden presentar fluctuaciones ilimitadas propias de modelos del tipo "paseo aleatorio" (*random walk*; [Royama, 1992](#)). Es decir, ante una perturbación externa como el cambio climático cabría esperar que los valores del rendimiento del cultivo se alejaran cada vez más de su valor promedio con el transcurso del tiempo, sin ningún signo de estabilización. Sin embargo, esto no es lo que solemos encontrar en los sistemas de cultivo.

La **persistencia** que observamos en el rendimiento de los cultivos es un **indicio de tal regulación interna**, pero aún nadie lo ha investigado. Además, cabe recordar que la regulación interna por retroalimentación es un **proceso usual en los organismos biológicos**, ocurren en los sistemas de control de la orientación en las plantas, y en los animales el control de la temperatura, la liberación de hormonas y la presión arterial, entre otros.

La existencia de procesos de regulación -internos- en la dinámica del rendimiento de los cultivos podría jugar un papel crucial en la **atenuación o amplificación de los impactos del cambio climático** sobre los cultivos. Detectar aquellos cultivos cuya dinámica del rendimiento está regulada y explicarla, podría ser un camino prometedor para desarrollar tecnologías de adaptación sinérgicas que aumenten el rendimiento agrícola al mismo tiempo que estabilice su variabilidad ([Iizumi & Ramankutty 2016](#)).

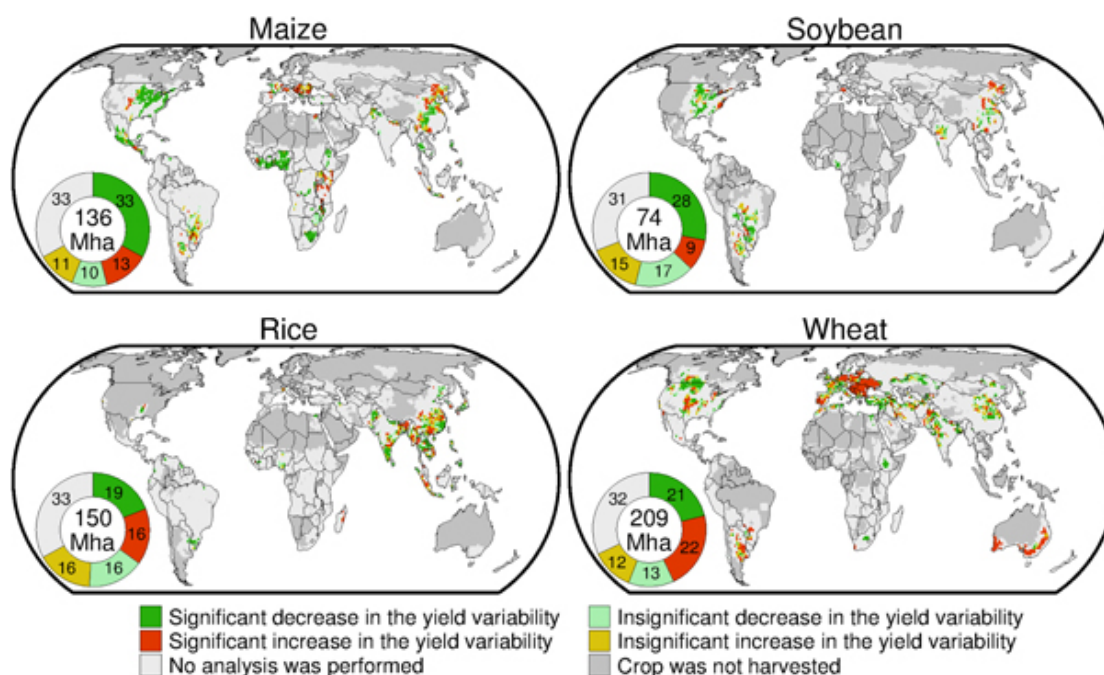


Figura 3. Cambios en la variabilidad del rendimiento durante 1981-2010 para los cuatro principales cultivos. Los diagramas de sectores indican los porcentajes del área cosechada global en las áreas coloreadas, normalizado al área cosechada global en 2000. *In* Iizumi & Ramankutty (2016).

1.2.2 Factores externos (climáticos y bióticos) al cultivo

A los desafíos anteriores se añade el impacto de los **factores externos (climáticos y no climáticos)** sobre el rendimiento de los cultivos. Alrededor del 20-30% de la variación en el rendimiento de los cultivos se explica por variaciones climáticas a nivel mundial ([Lobell & Field 2007](#), [Ray et al. 2015](#), [Iizumi & Ramankutty 2016](#)). En las zonas más productivas puede aumentar hasta un 60% (e.g. cinturón del maíz de los EEUU), porque los cultivos intensivos (que necesitan grandes insumos, ej. fertilizante) suelen ser los más sensibles a los cambios climáticos debido a la ausencia de otros factores limitantes ([Schlenker & Lobell 2010](#)). Incluso, se espera que cada

década adicional de cambio climático disminuya en un 1% el rendimiento medio de los cultivos, lo cual es una fracción pequeña pero no trivial dada la estimación inicial de un aumento del 14% por década en la productividad de los cultivos para asegurar la producción alimentaria global ([Porter et. al. 2014](#)).

Veamos **cómo afectan** estas perturbaciones externas al rendimiento de los cereales, **cómo han cambiado** estos factores en los últimos años y **qué se espera que ocurra** en el futuro. Comenzaremos con los **3 principales factores climáticos / ambientales** que afectan y continuarán afectando a la producción de los cultivos en las próximas décadas: el aumento de la temperatura, los cambios en el régimen de precipitaciones y el aumento del nivel atmosférico de CO₂. Luego comentaremos otros factores externos de gran importancia, como el riego y factores bióticos como las malezas.

Temperatura

La temperatura es un factor **esencial** en el cultivo. Junto con los niveles de luz, dióxido de carbono, humedad del aire, agua y nutrientes, la temperatura influye en el **crecimiento** y en el **desarrollo** de las plantas ([Hatfield et al. 2011](#)). La mayoría de los **procesos biológicos** de las plantas se **aceleran** al aumentar las temperaturas, lo cual puede ser positivo o negativo para la **productividad** de las cosechas dependiendo del resto de factores que determinan el rendimiento del cultivo ([Stone 2001](#)).

Según Lobell & Gourdji ([2012](#)) la temperatura afecta al **rendimiento** de los cultivos a través de **5 caminos principales**:

- I. Cada especie tiene un **rango de temperatura específico** representado por un mínimo, máximo y óptimo: 15°C para trigo o cebada, 18° para maíz, 22° para soja, 23° para arroz y 25° para sorgo ([Hatfield et al. 2011](#), [Lobell et al 2011](#)). A medida que las

temperaturas aumentan el desarrollo del cultivo se acelera. Un desarrollo más rápido en cultivos no perennes genera un ciclo de vida más corto y plantas más pequeñas con una duración de la fase reproductiva más breve ([Iqbal et al. 2009](#), [Lobell et al. 2013](#)). Como consecuencia el rendimiento potencial del cultivo se reduce ([Stone 2001](#), [Moriondo et al. 2011](#)) debido a la menor intercepción de luz acumulada y menor tiempo para acumular los carbohidratos, grasas y proteínas que constituyen el grueso de frutos y granos ([Qaderi & Reid 2009](#)) durante el período de crecimiento.

- II. En segundo lugar, la tasa fotosintética y la respiración de las plantas aumentan con la temperatura del aire, aunque existen rangos óptimos de temperatura (ej. para la fotosíntesis se encuentra entre 20-25 °C para los principales cultivos templados). Este efecto es menor en los cultivos C4 que tienen un óptimo de temperatura mayor para la fotosíntesis respecto a los cultivos C3, pero para temperaturas altas los impactos negativos se igualan ([Crafts-Brandner and Salvucci, 2002](#)). Asimismo, el calentamiento durante la noche aumenta los costos de respiración sin beneficio para la fotosíntesis.
- III. Tercero, el calentamiento **exacerba el estrés hídrico que sufre el cultivo** debido a un aumento exponencial de la presión de vapor de saturación del aire y el déficit de presión de vapor entre aire y hoja.
- IV. Cuarto, las **temperaturas extremas** pueden **dañar directamente** las células de las plantas y pueden producir **esterilidad** ([Teixeira et al. 2012](#)). Temperaturas extremadamente altas durante el día son dañinas y ocasionalmente letales para los cultivos ([Porter & Gawith, 1999](#)). Los rendimientos de los cultivos más importantes disminuyen precipitadamente a temperaturas por encima de los 30 °C ([Schlenker & Roberts 2009](#)). Por ejemplo, temperaturas superiores a 32-34 °C después de la floración parecen acelerar la **senescencia** rápidamente en el trigo ([Lobell et al. 2012](#)). Sin embargo, el resultado sobre el rendimiento del cultivo dependerá de la **duración de la exposición** a altas temperaturas, donde los impactos de períodos prolongados de temperaturas más allá del óptimo para el

desarrollo no son tan bien entendidos ([Craufurd & Wheeler, 2009](#)).

Por su parte, el daño por **heladas** es una limitación importante en el crecimiento de muchos cultivos, y se han observado reducciones significativas en la aparición de heladas desde 1961 que se atribuyen a emisiones de gases de efecto invernadero en casi todas las regiones del mundo ([Zwiers et al. 2011](#)).

- V. Cuando el aumento de la temperatura se acompaña de **mayor CO₂** atmosférico puede favorecer el **crecimiento y supervivencia de pestes y enfermedades** específicas de los cultivos ([Ziska et al. 2010](#)).

Este **calentamiento** ha tenido en general un **efecto negativo** en la producción de los cultivos, disminuyendo los rendimientos de los cereales básicos como el trigo, el arroz y el maíz, aunque con diferencias entre regiones y latitudes ([Porter et al. 2014](#)) como veremos más adelante. El estudio a escala mundial de Lobell et al. ([2011](#)) estimó que el impacto del calentamiento sobre los cultivos para el período 1980 - 2008, ha provocado que la mayoría de las áreas de trigo y maíz estén **más allá de su óptimo de temperatura**, reduciendo sus rendimientos aproximadamente en un 5.5% y un 3.8%, respectivamente. En términos absolutos, esto equivale a la producción anual de maíz en México (23 MT) y trigo en Francia (33 MT), respectivamente, y junto con el impacto estimado sobre la cebada representan aproximadamente 40 millones de toneladas o \$5 mil millones dólares por año, a partir de 2002 ([Lobell & Field 2007](#)). Más aún, Lobell et al. ([2011](#)) observaron una **mayor variabilidad de la temperatura** que redujo los rendimientos de los cultivos en hasta un 10%, excepto en los países de alta latitud, donde el arroz en particular se beneficia del calentamiento.

La **temperatura mínima y máxima** durante el período de crecimiento de los principales cultivos ha aumentado en la mayoría de las regiones cerealeras, con una tasa de 0.3°C por década ([Lobell et al. 2011](#), [Lobell & Gourdji 2012](#); Figura 4). Un ejemplo es la **ola de calor** durante el verano del 2003 ([Schär et al. 2004](#)), que redujo la producción de cereales en Europa en

23 MT con respecto a 2002. La razón de esta reducción se atribuyó a una temporada de crecimiento más corta combinada con una mayor frecuencia de eventos extremos, tanto en términos de temperaturas máximas como de periodos de sequía más largos ([Olesen & Bindi 2004](#)). El aumento de la **frecuencia de noches inusualmente calientes** desde 1961 ([Bindoff et al. 2013](#)) ha sido dañina para la mayoría de los cultivos, pero principalmente para el arroz ([Peng et al. 2004](#), [Wassmann et al. 2009](#), [Welch et al. 2010](#)).

Según el IPCC ([2014](#)) la **temperatura superficial aumentará** durante el siglo XXI en todos los escenarios de emisiones evaluadas. Es muy probable que las **olas de calor** ocurran más a menudo y duren más. Los extremos fríos invernales ocasionales continuarán ocurriendo. A corto plazo, se espera un **impacto negativo** en la producción de los principales cultivos (trigo, arroz y maíz) en las **regiones tropicales y templadas** para aumentos de temperaturas locales en 2°C o más, aunque algunas localizaciones individuales pueden beneficiarse ([Porter et al. 2014](#)). Después del 2050 es probable que aumente el riesgo de **impactos climáticos más severos** y la producción de cultivos se vea afectada de manera constante y negativa en los países de **baja latitud**, mientras que en las **latitudes septentrionales** pueda tener efectos positivos o negativos con el calentamiento global ([Porter et al. 2014](#)).

Los impactos proyectados varían para los distintos tipos de cultivos. Zhao et al. ([2017](#)) calculan que un aumento de 1°C de la temperatura media global **reduciría** en un 6,0% los rendimientos globales de **trigo**, el arroz en un 3,2%, el maíz en 7,4% y la soja en un 3,1% (sin considerar los efectos de la fertilización con CO₂ ni medidas de adaptación efectiva o mejoramiento genético).

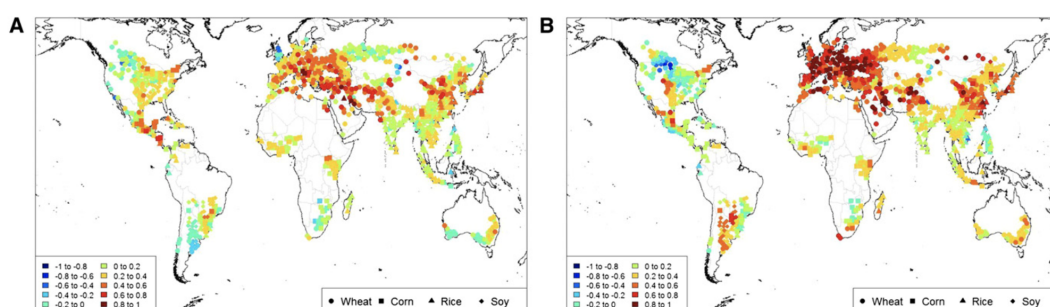


Figura 4. Tendencias de calentamiento (°C por década) desde 1980 en la temperatura mínima (A) y máxima (B) diaria durante el período de crecimiento de cada cultivo en las principales regiones cerealeras del mundo. Los distintos tipos de puntos indican el cultivo dominante para cada celda de la grilla. *In* Lobell & Gourdji ([2012](#)).

Precipitación

El agua y la seguridad alimentaria están estrechamente relacionadas. El agua constituye, por intermedio de las disoluciones del suelo, un elemento esencial para la **nutrición de las plantas** y para el **mantenimiento de su estructura**, proporciona turgencia a los tejidos y órganos ([Kramer & Boyer 1995](#)).

Las **precipitaciones** pueden permitir que se alcancen rendimientos óptimos en los cultivos o pueden impedirlo, según la **cantidad de lluvia** y su **distribución** (en el tiempo y en el espacio). El **déficit de humedad del suelo** puede disminuir la disponibilidad de los nutrientes para el cultivo a pesar de que se encuentren en cantidades suficientes. Por su parte, el **exceso de la humedad del suelo** genera condiciones anóxicas, aumento del riesgo de enfermedades y retrasa los períodos de plantación y cosecha, al tiempo que puede ocasionar daños directos por inundaciones ([Rosenzweig et al. 2002](#)).

En las últimas décadas la **intensidad de la precipitación** ha aumentado en varias regiones ([Milly et al. 2002](#), [Alexander et al. 2006](#), [Min et al. 2011](#)). La **distribución de las lluvias** durante el período de crecimiento es crucial particularmente en los trópicos semiáridos ([Porter et al. 2014](#)), pero también en EEUU donde las inundaciones han perjudicado el rendimiento del maíz ([Rosenzweig et al. 2002](#)). Sin embargo, hasta ahora los **impactos estimados** de la precipitación sobre los cultivos han sido

relativamente pequeños a escala global, al menos en comparación con la variabilidad de la temperatura ([Lobell & Burke 2008](#), [Lobell et al. 2011](#)). El impacto proyectado para el calentamiento en 2 °C se calcula en una pérdida de rendimiento del 14.4%, mientras que el efecto de reducir la precipitación en un 20% se estima en una reducción del rendimiento del 5.8% para distintos cultivos ([Lobell & Burke 2010](#)). Este resultado parece contraintuitivo, pero puede deberse a que:

- I. La precipitación exhibe **mayor variabilidad espacial** que la temperatura, las variaciones temporales en el promedio espacial de la precipitación tienden a disminuir a medida que el dominio espacial se amplía ([Porter et al. 2014](#)). Como resultado, la precipitación se vuelve menos importante como un predictor de los rendimientos de los cultivos a gran escala ([Lobell & Field, 2007](#), [Li et al. 2010](#)).
- II. La variabilidad de la precipitación ocurre principalmente durante el período **intra-anual** mientras que los estudios se suelen realizar con datos de rendimiento anual del cultivo.
- III. **Las tendencias de temperatura son grandes** en relación a su variabilidad histórica y por tanto son más importantes que las tendencias de precipitación en la conducción de modelos de predicción ([Lobell & Burke 2010](#)).
- IV. Además existen **problemas metodológicos**. Los modelos de proyección del cambio climático suelen dar predicciones precisas de la respuesta del cultivo a la temperatura, pero malas predicciones sobre los efectos de la lluvia ([Rosenzweig et al. 2002](#), [Lobell & Burke 2010](#)).
- V. También existe evidencia de que en aquellas zonas donde aumentan los cultivos bajo **riego**, la influencia de la temperatura sobre los rendimientos comienza a dominar en relación a la precipitación ([Hawkins et al. 2012](#)).
- VI. El impacto de la **sequía** en el rendimiento de los cultivos es un tema de investigación más común que el impacto de las **inundaciones**, que están poco estudiadas ([Porter et al. 2014](#)).

A futuro, se prevé una **disminución de las precipitaciones** en varias regiones, con el consiguiente **aumento de la probabilidad de sequías**, lo cual a su vez es probable que aumente el **estrés hídrico** de los cultivos ([Porter et al. 2014](#), Figura 5). Se esperan también cambios en el momento de la estación lluviosa en zonas tropicales ([Stone 2001](#), [Hatfield et al. 2011](#)), donde los eventos de lluvia extrema pueden ser muy peligrosos para los cultivos al generar **inundaciones y abnegación en los suelos** ([Lobell & Gourdjji 2012](#)).

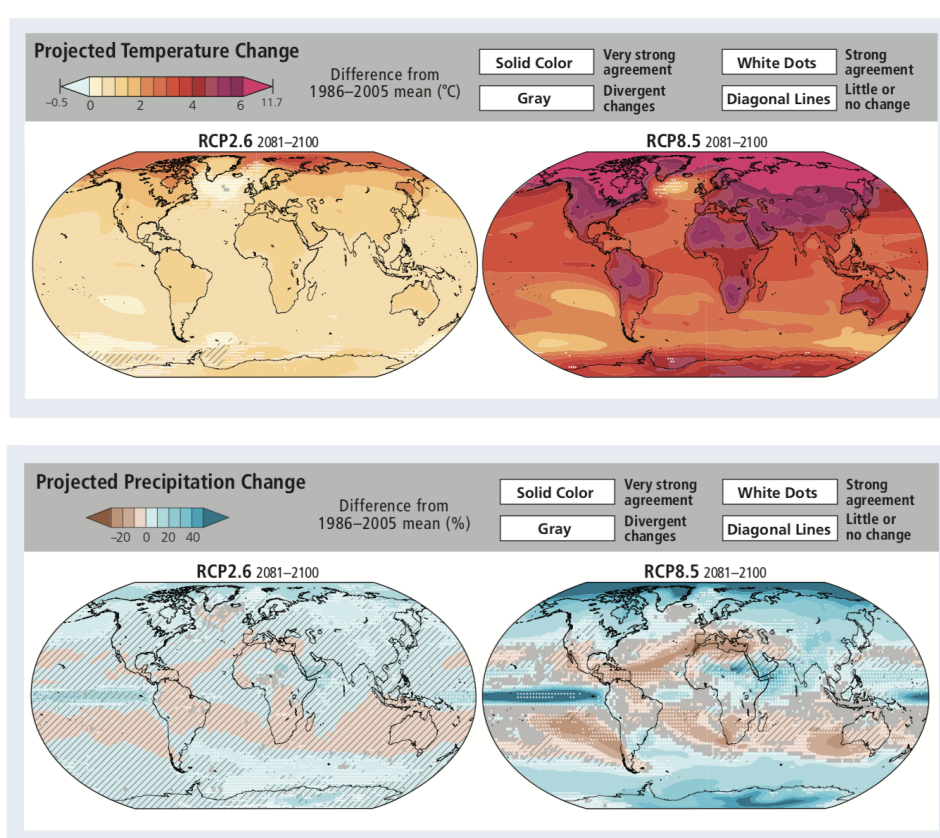


Figura 5. Cambios proyectados de los promedios anuales de la temperatura superficial (A) y la precipitación (B), para 2081-2100 respecto a 1986-2005, bajo altas emisiones continuas (RCP8.5) y bajo una mitigación ambiciosa (RCP2.6). *In* IPCC 2014.

Detalles técnicos: Se observan los resultados del Proyecto de Intercomparación de Modelos Acoplados (CMIP5) de 32 modelos para RCP2.6 y 39 modelos para RCP8.5. Los colores sólidos indican áreas con un acuerdo muy fuerte, donde el cambio medio multimodelo es mayor que el doble de la variabilidad de referencia (la variabilidad interna natural en 20 años significa) y $\geq 90\%$ de los modelos coinciden en el signo del cambio. Los colores con puntos blancos indican áreas con fuerte acuerdo, donde $\geq 66\%$ de los modelos muestran un cambio mayor que la variabilidad de la

línea de base y $\geq 66\%$ de los modelos coinciden en el signo del cambio. En gris se indica áreas con cambios divergentes, donde $\geq 66\%$ de los modelos muestran un cambio mayor que la variabilidad de la línea de base, pero $< 66\%$ está de acuerdo con la señal de cambio. Los colores con líneas diagonales indican áreas con poco o ningún cambio, donde $< 66\%$ de los modelos muestran un cambio mayor que la variabilidad de la línea base, aunque puede haber cambios significativos en escalas de tiempo más cortas, como estaciones, meses o días. In [IPCC 2014](#), Figure SPM.7 p.12.

Dióxido de carbono atmosférico (CO₂)

Los efectos del CO₂ en el crecimiento y desarrollo de los cultivos son varios, pero los más importantes probablemente podrían agruparse bajo las categorías de **fijación biológica de nitrógeno**, **fotosíntesis**, **eficiencia en el uso del agua** y finalmente sobre el **rendimiento del cultivo** ([Kimball & Idso 1983](#)). Un aumento del CO₂ puede incrementar en cierta medida el **rendimiento del cultivo** a través de la estimulación de la **ganancia de carbono fotosintético** (ej. fertilización) y la **eficiencia del uso del agua**, principalmente, pero luego la respuesta se estanca (Figura 6; [Long et al. 2006](#)). Su efecto depende de la especie y tipo de cultivo (se observa una **mayor respuesta en especies C₃** -soja, arroz, trigo, girasol, cebada, avena- que en las de tipo C₄ -maíz, sorgo-; [DaMatta et al. 2010](#)), y de otros factores como la temperatura, la disponibilidad de agua y nutrientes.

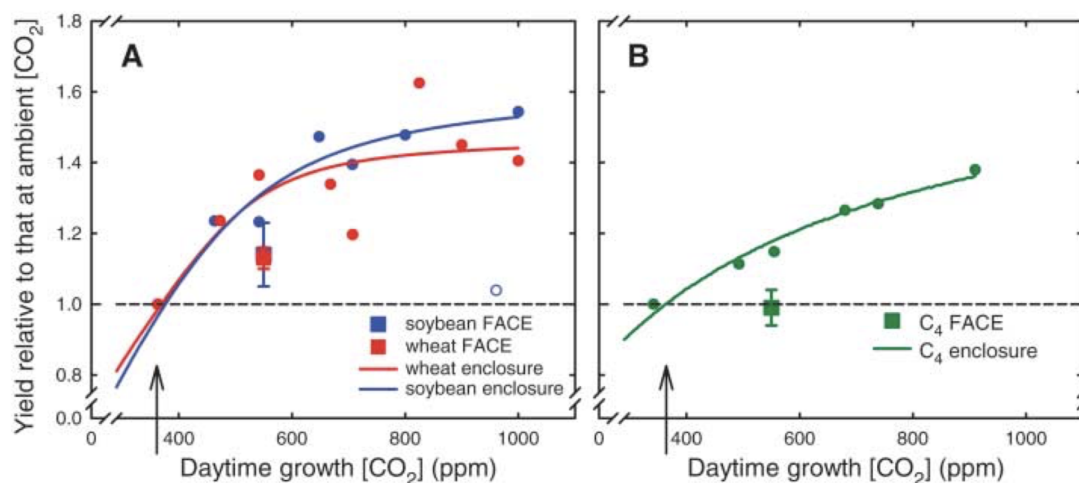


Figura 6. Efectos del aumento de la concentración de CO₂ en el rendimiento de los cultivos. Los datos muestran el rendimiento de

los cultivos en sistemas con elevado CO₂ en relación con aquellos con CO₂ ambiental (flechas) para (A) la **soja** en cámaras (círculos azules sólidos) y FACE (cuadrado azul, escondido detrás del cuadrado rojo) y **trigo** en cámaras (círculos rojos) y FACE (cuadrado rojo); y (B) **cultivos C4** (maíz y sorgo combinados) en cámaras (círculos verdes) y estudios FACE (cuadrado verde). Las barras de error indican los intervalos de confianza para la media al 90% de confianza para los estudios FACE. Las líneas continuas son los ajustes por mínimos cuadrados para la respuesta hiperbólica no rectangular del rendimiento al crecimiento del CO₂ de estos estudios. *In* Long et al. ([2006](#)).

La concentración del CO₂ atmosférico ha **aumentado** en un 39% desde el comienzo de la era industrial, más de 100 ppm ([Global Carbon Project 2011](#)). A pesar de este notable aumento, históricamente los beneficios del aumento del CO₂ han desempeñado un **papel secundario** sobre las tendencias globales del rendimiento ([Amthor 2001](#), [Lobell et al. 2011](#)). Se cree que el aumento del CO₂ ha mejorado la eficiencia del uso de agua y los rendimientos de los cultivos, especialmente en plantas C₃ como el trigo y el arroz ([Porter et al. 2014](#)). Sin embargo, existe una gran discusión sobre el efecto estimulante del CO₂ sobre el rendimiento de los cultivos ([Ainsworth & Long 2005](#), [Long et al. 2006](#), [Leakey 2009](#), [DaMatta et al. 2010](#)). Los análisis del efecto del CO₂ en los cultivos deben ser mirados con precaución ya que se basan en unos pocos estudios realizados en cámaras de campo o FACE (*Free Air Concentration Enrichment*; [Erbs et al. 2010](#), [Slingo et al. 2005](#)) que no tienen en cuenta la variabilidad temporal del CO₂ ([Bunce 2012](#)) y están limitados a condiciones ambientales específicas (generalmente se desarrollan en EE.UU. y en China, [Porter et al. 2014](#)). También se indica que el aumento del CO₂ ha sido globalmente uniforme, que no existe variación espacial y que por tanto es difícil analizar sus efectos ([Long et al. 2006](#)). Hacen falta largas series temporales del nivel

de CO₂ y a escalas menores para evaluar de manera precisa su impacto sobre los cultivos.

El aumento de los niveles de CO₂ atmosféricos **pueden beneficiar a los rendimientos de los cultivos a corto plazo** aumentando sus tasas fotosintéticas ([Porter et al. 2014](#)). Sin embargo, los beneficios del enriquecimiento de CO₂ pueden ser **menores a los proyectados en las últimas décadas** ([Ainsworth & Long 2005](#), [Long et al. 2006](#), [Leakey 2009](#)). Existe aún una **gran incertidumbre sobre la magnitud su efecto** y de su **interacción con otros factores**, que pueden generar respuestas complejas en el rendimiento del cultivo **difíciles de predecir** ([Erda et al. 2005](#), [Long et al. 2006](#), [Porter et al. 2014](#)). Por ejemplo, los estudios en ambientes controlados (FACE) han mostrado que el aumento del rendimiento del cultivo al aumentar el CO₂ está limitado tanto para **temperaturas bajas** ([Shimono et al. 2008](#), [Hasegawa et al. 2013](#)) como para **temperaturas altas** ([Porter et al. 2014](#)). Por otra parte, los cultivos con **estrés hídrico** responden de manera más acentuada al aumento del CO₂ respecto a los cultivos con riego, debido a que el CO₂ favorece la resistencia de los estomas a la pérdida de agua durante los intercambios gaseosos ([Ainsworth & Long 2005](#)). Esto sugiere que los cultivos de **secano** se verán beneficiados con el aumento del CO₂ en relación a los cultivos de **regadío** ([McGrath & Lobell, 2011](#)) o, lo que es lo mismo, no se espera que el aumento del CO₂ mejore el rendimiento de los cultivos de regadío. Sin embargo, esta respuesta no se observa de forma consistente entre los distintos modelos y los meta-análisis de estudios FACE, por lo que se piensa que la relación entre el estrés hídrico y la asimilación **puede variar con la escala espacial** ([Challinor & Wheeler, 2008](#)).

Eventos climáticos extremos

Los eventos climáticos extremos **durante la temporada de crecimiento** pueden tener graves consecuencias en los cultivos, y cuando se

producen durante **etapas claves de desarrollo** (e.g. antesis) pueden tener un efecto dramático ([Wheeler et al. 2000](#), [Lobell & Gourdji 2012](#)). Se tratan de episodios, sucesos o eventos meteorológicos que son **raros**, o infrecuentes, según su **distribución histórica para un lugar determinado**. Existen diferentes definiciones de “raro” pero, de manera general en el IPCC ([2012](#)) se afirma que un evento meteorológico extremo normalmente ocurre cuando una variable climática se encuentra por encima (o por debajo) de un valor umbral cerca de los extremos superiores (o inferiores) del rango de valores observados de la variable (la definición completa se proporciona en la Tabla 3-1, p.116 del Informe). Es importante analizar la **magnitud** de los extremos climáticos, su **frecuencia y el momento** en el que ocurren estos eventos así como su **interacción con otros factores** que influyen en el cultivo ([Slingo et al. 2005](#)).

A pesar de que los fenómenos extremos siempre han existido, el **aumento de su frecuencia y de la intensidad** de algunos de ellos se revela como un hecho **preocupante en algunas regiones** ([IPCC 2012](#)). Desde 1950 existe una mayor frecuencia de días cálidos extremos y menor frecuencia de días fríos extremos asociados con un clima más cálido, una disminución en el rango de temperatura diurna asociado con temperaturas nocturnas más altas, mayor intensidad de precipitación, mayor sequía en verano en el centro del continente, entre otros (Easterling et al. [1997](#), [2000a](#), [200b](#), [Alexander et al. 2006](#), [IPCC 2012](#)). En particular, el número de olas de calor se ha incrementado en gran parte de Europa, Asia y Australia, y la frecuencia de eventos de fuertes precipitaciones se ha incrementado en Norteamérica y en Europa ([IPCC 2012](#)).

A futuro se espera que el cambio climático traiga temperaturas aún más cálidas; cambios en los patrones de lluvia; y una mayor frecuencia, y tal vez gravedad de condiciones meteorológicas extremas ([Tebaldi et al. 2006](#), [IPCC 2012](#)). Sin embargo, los eventos climáticos extremos y su duración a menudo se descuidan en los escenarios de impacto del cambio climático sobre la seguridad alimentaria ([Semerov & Porter 1995](#)), en parte

debido a que son difíciles de calibrar ([IPCC 2012](#)). Al no considerar el efecto de los **eventos climáticos extremos** sobre el rendimiento de los cultivos se suelen generar **estimaciones sesgadas** ([Schlenker & Roberts 2009](#)). Los estudios que sí incluyen explícitamente este tipo de eventos predicen impactos negativos sobre el rendimiento de los cultivos, su estabilidad y calidad ([Porter & Semenov 2005](#), [Moriondo et al. 2011](#) -para el girasol en el Mediterráneo-).

Respuestas regionales del rendimiento del cultivo ante el cambio climático

El impacto del cambio climático sobre el rendimiento de los cereales suele **variar entre regiones**, dependiendo entre otras cosas de las diferencias en el clima de base, el manejo agrícola, el tipo de suelo, la duración y el momento de la exposición del cultivo a diversas condiciones ambientales ([Porter et al. 2014](#)). Los efectos del cambio climático sobre la producción agrícola son **evidentes en varias regiones del mundo**, siendo los **impactos negativos** más comunes que los positivos ([Porter et al. 2014](#)). Las tendencias positivas solo ocurren en algunas regiones de **latitud alta** debido a que se verán beneficiadas al tener períodos de crecimiento libres de heladas ([Iqbal et al. 2009](#)).

A menudo se encuentran **incongruencias en la respuesta del cultivo entre distintas regiones**. Por ejemplo, los rendimientos del arroz en China están positivamente correlacionados con la temperatura en algunas regiones y correlacionados negativamente en otras (Zhang et al. [2008](#), [2010](#)). Los autores señalan que esta diferencia podría deberse a una correlación positiva entre la temperatura y la **radiación solar** en el primer caso, y una correlación negativa entre la temperatura y el **estrés hídrico** en el último caso. Esto señala la necesidad de considerar las **interacciones entre distintas variables climáticas y/o posiblemente con el propio rendimiento del cultivo** para evaluar las diferencias regionales en el impacto del clima.

Existe actualmente un debate considerable acerca de **cuándo los impactos netos del cambio climático sobre los cultivos serán negativos**. A **corto plazo**, para el período 2030-2049, alrededor del 10% de las proyecciones indican **ganancias** de más del 10%, mientras que cerca del 10% de las proyecciones muestran **pérdidas** de rendimiento de más del 25%, en comparación con el final del siglo XX ([Porter et al. 2014](#)). Esto dependerá de qué tan rápido cambien los efectos del calentamiento y del CO₂, y de qué tan resiliente sea el cultivo ([Lobell & Gourdji 2012](#)). Los primeros estudios de Rosenzweig & Parry ([1994](#)) mostraron que en general los rendimientos de los **principales cultivos** (trigo, arroz, maíz y soja) aumentarán en el **norte de Europa**, y **disminuirán en África y Sudamérica**. Más recientemente, algunos trabajos señalan el **sur de Asia y el sur de África** como dos regiones que, en ausencia de adaptación, para el 2050 sufrirían los impactos más negativos en varios cultivos importantes (e.g. trigo, maíz y sorgo; [Lobell et al. 2008](#)). El cambio climático afectará también a los cultivos de **América Central, noreste de Brasil y parte de la región Andina** ([Iqbal et al 2009](#)). Se espera que los países en desarrollo (fuertemente dependientes del clima en su agricultura) sean los más vulnerables al cambio climático ([Porter et al. 2014](#)). Luego, **a mediados de siglo**, es probable que los beneficios del CO₂ disminuyan y los efectos dañinos del cambio climático sean mayores para los cultivos ([Easterling et al. 2007](#)). Los aumentos de la temperatura mundial de ~4°C o más por encima de los niveles de finales del siglo XX, combinados con el aumento de la demanda de alimentos, plantearían grandes riesgos a la seguridad alimentaria a nivel mundial y regional ([Porter et al. 2014](#)).

Uno de los retos a la hora de asegurar la producción alimentaria mundial es superar la **brecha entre escalas espaciales de estudio**. Las incertidumbres espaciales pueden cancelarse en países con grandes áreas cosechadas cuando los datos se agregan a escala nacional ([Porwolik et al. 2017](#)). Por ejemplo, al utilizar únicamente las estadísticas nacionales de cultivos los rendimientos de trigo estadounidenses se ha estimado un aumento en todas partes en ~0.01 tons / ha · año² (0.3% / año) entre 1999 y

2008, mientras que al utilizar escalas subnacionales se identificó que en el ~36% de las áreas cosechadas de trigo en los Estados Unidos (~7 millones de hectáreas) los rendimientos no han mejorando; solo en el ~64% restante de la tierra de trigo (~13 millones de ha) los rendimientos están mejorando, y a diferentes tasas identificables ([Ray et al. 2012](#)). Además, debido a que a menores escalas los impactos del cambio climático sobre los cultivos siguen siendo **altamente inciertos** ([Porter et al. 2014](#)), resulta imprescindible **mejorar este aspecto en nuestros modelos**. Es necesario considerar proyectos diseñados a escalas inferiores para poder **contextualizarlos dentro del "panorama general"**. Existen claras ventajas, a esta escala: podemos evaluar la heterogeneidad climática dentro del país, algunas **estrategias de adaptación** pueden resultar más eficaces y algunos problemas de **gestión ambiental** sólo se manifiestan a este nivel espacial (ej. el agotamiento de los recursos hídricos).

El riego de los cultivos

El riego es actualmente responsable de la extracción de unos **2.800 km³ al año** de aguas subterráneas, lagos y ríos; se utiliza en aproximadamente el **24% de las tierras de cultivo** y es responsable de suministrar el **34% de la producción agrícola** mundial ([Siebert & Döll 2010](#)). De hecho, sin riego, la producción mundial de cereales disminuiría en un 20%, por lo que se necesitaría más tierra para producir la misma cantidad de alimentos.

Los **sistemas bajo riego** generalmente se ven **menos afectados** por el aumento de la temperatura máxima respecto a sistemas de secano, debido principalmente a que el riego **previene el estrés hídrico** y a que las mayores tasas de respiración ayudan a enfriar las hojas y prevenir pérdidas relacionadas con el **daño directo** de la temperatura ([Schlenker & Roberts 2009](#)). Este efecto explicaría el beneficio del arroz ante mayores temperaturas máximas en varias localidades, al menos hasta ciertos valores,

y también los daños causados por el aumento de la temperatura mínima ([Welch et al. 2010](#)). Sin embargo, ambos tipos de cultivos (de secano y regadío) pueden comportarse de manera similar en **zonas muy húmedas**.

Se espera que el riego juegue un **papel clave en la capacidad de adaptación** de la agricultura ante el cambio climático ([Piao et al., 2010](#), [Porter et al. 2014](#)). Sin embargo, las **limitaciones en la disponibilidad de agua y los cambios en su uso** para satisfacer la creciente demanda de la población, afectarán esta capacidad ([Slingo et al. 2005](#), [Mueller et al. 2012](#)). Debemos entonces **reducir la brecha del rendimiento entre los cultivos** de regadío y secano ([Sadras 2015](#)). En la mayoría de los cultivos de regadío los rendimientos alcanzan el 80% del rendimiento potencial (el rendimiento máximo alcanzable por un cultivo en situaciones sin limitaciones por recursos), mientras que en los cultivos de secano no supera el 50% ([Lobell et al. 2009](#)). La figura 7 muestra las **regiones del mundo** donde se proyecta un **mayor requerimiento neto de riego** debido al impacto del cambio climático. El sur de Europa y el sur-este de Asia son las zonas que van a demandar más agua para riego de sus cultivos. Necesitamos **comprender los efectos del riego sobre estas brechas del rendimiento en el contexto del cambio climático** para enfrentar el desafío de la seguridad alimentaria ([Mueller et al. 2012](#)). Esto nos permitirá **aumentar la eficiencia del uso del agua para riego y guiar la intensificación sostenible de la agricultura** ([van Ittersum et al. 2013](#)).

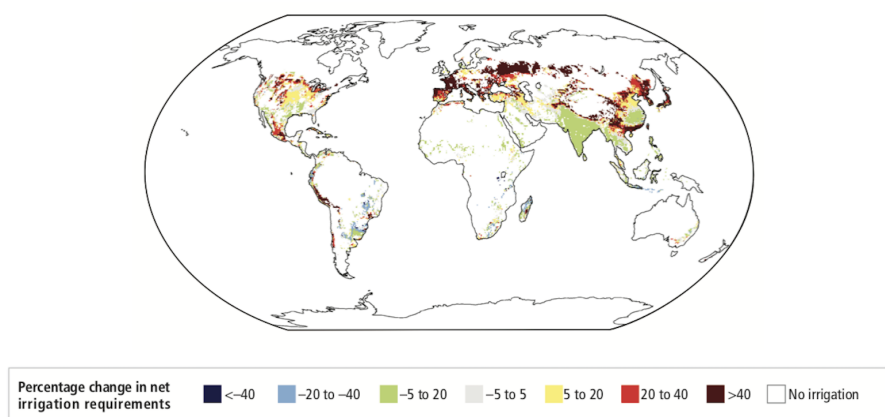


Figura 7. Cambio porcentual en los requerimientos netos de riego debido al impacto del cambio climático, para los 11 cultivos principales desde 1971-2000 hasta 2070-2099 en áreas actualmente equipadas para riego, asumiendo las prácticas actuales de manejo. Se muestra la mediana del cambio pronosticado según 19 Modelos de Circulación General (MCG, basados en el escenario de emisiones A2 de Escenarios de Emisión Especiales, SRES) utilizados para forzar un modelo de vegetación e hidrología. *In* IPCC ([2014](#)).

Factores bióticos: malezas

El efecto del cambio climático tiene una profunda influencia sobre la sanidad vegetal, impactando sobre **plagas, enfermedades y malezas**. El impacto es variable, pero afecta principalmente su distribución geográfica, su ciclo vital y su relación con los cultivos ([Porter et al. 2014](#)).

Las malezas **producen la mayor pérdida potencial de rendimiento en los cultivos** (34%) respecto a las plagas y enfermedades ([Oerke 2006](#)), y **compiten con los cultivos** por los recursos (agua, luz y nutrientes; [Ziska 2003](#)). El incremento de CO₂ puede afectar a la **relación competitiva** entre la mala hierba y el cultivo, si bien el resultado final puede ser en detrimento del cultivo o a su favor. La literatura científica presenta algunos casos de esa **ambivalente relación**. Así, por ejemplo, el crecimiento del cenizo (*Chenopodium album*) en cultivo de soja es favorecido por el incremento del CO₂ atmosférico ([Ziska 2003](#)), lo que indica que probablemente será un fuerte competidor de dicho cultivo. Con respecto al control de las malezas, varios estudios han indicado una **disminución de la eficacia de los herbicidas** para algunas especies de malezas en respuesta al aumento del CO₂ y/o la temperatura, tanto en el tipo C3 como en C4 ([Archambault 2007](#), [Manea et al. 2011](#)).

Se prevé que el **impacto de las malezas** sea aún mayor en el futuro ([Porter et al. 2014](#)). Los cambios en el clima y la concentración de CO₂ **aumentarán la distribución geográfica y la competitividad** de las malezas, e incluso pueden continuar **reduciendo la eficacia de algunos herbicidas** ([Porter et al. 2014](#)). Por ejemplo, se pronostica una migración de malezas invasoras hacia el norte en Norteamérica ([Ziska et al. 2011](#)) debido al aumento de las temperaturas superficiales. También se espera un desplazamiento hacia el norte de Europa de la avena loca (*Avena sterilis*) una especie importante en cultivos cerealistas ([Castellanos et al. 2014](#)).

Por otra parte, las malezas también **proveen funciones y servicios ecosistémicos que pueden favorecer la producción de los cultivos** ([Altieri 1999](#), [Marshall et al. 2003](#)). Por ejemplo, las malezas pueden mejorar la conservación del suelo y el agua, el ciclo de nutrientes, la actividad de polinización, proporcionar fuentes de alimento para animales e insectos y contener agentes de control biológico ([Marshall et al. 2003](#)). Cabe destacar que existen alrededor de unas 260.000 especies de plantas, de las cuales unas 10.000 son consideradas malezas ([Rapoport 1991](#)).

La **comprensión del efecto de las malezas** y su interrelación con los factores abióticos sobre los cultivos permitirán una mejor adaptación de los mismos. Desde un punto de vista de **control y manejo** de las malezas en un contexto de cambio climático, será necesario la formulación de estrategias nuevas y más integradas, así como potenciar la prevención de la entrada, establecimiento y dispersión de nuevas especies exóticas. Desde un punto de vista de aprovechar las **funciones y servicios ecosistémicos** que provee una comunidad de malezas diversa, debemos identificar los niveles que es deseable mantener y/o mejorar para aumentar el rendimiento del cultivo. Esto puede ser el primer paso para equilibrar las necesidades de control de malezas con los requisitos de biodiversidad y métodos de producción más sostenibles ([Marshall et al. 2003](#)).

1.3 Modelos estadísticos para comprender y predecir el rendimiento de los cultivos

Series históricas

La comprensión de los impactos de las tendencias climáticas **pasadas** sobre los cultivos puede ayudarnos a medir la importancia del cambio climático a **corto plazo** para la seguridad alimentaria ([Lobell et al. 2011](#)). Por ello, en esta tesis nos centraremos en comprender las respuestas de los cultivos mediante **modelos explicativos** antes de emprender el reto de realizar **modelos de predicción**.

Para la construcción de nuestros modelos utilizaremos **largas series históricas** de los **rendimientos** de los principales cereales, de las variables **climáticas** durante el período de crecimiento del cultivo (medias y valores extremos mensuales) y adicionalmente de variables bióticas (diversidad de malezas).

A continuación vamos a comentar las **aproximaciones tradicionales** que se han propuesto en la bibliografía reciente y las diferencias más importantes con el **enfoque planteado en esta tesis**.

Aproximaciones tradicionales

Para investigar las relaciones entre el rendimiento de los cultivos y la variabilidad climática se pueden utilizar **correlaciones** (ver Zhang et al. [2008](#), [2010](#)), **modelos basados en procesos** o de simulación de cultivos (ej. *Crop Environment Resource Synthesis*, CERES, para el maíz; ver [Rosenzweig et al. 2002](#), [Erda et al. 2005](#)) y **modelos estadísticos** (ver [Lobell & Burke](#)

[2010](#), Lobell et al. [2011a](#), [2011b](#)). Es posible generar pronósticos bastante buenos a corto plazo mediante modelos correlacionales, pero con ellos es **imposible comprender y controlar problemas dinámicos** porque **no son modelos causales** ni nos permiten modelar la forma de dependencia. Para predecir los efectos potenciales del cambio climático en el rendimiento de los cultivos **necesitamos un modelo que incluya cómo los cultivos responden al clima** ([Lobell & Burke 2010](#)). Los modelos basados en procesos son un enfoque ampliamente utilizado para este problema de predicción, emulan los principales procesos de crecimiento y desarrollo de los cultivos y son probados experimentalmente. Sin embargo, estos modelos también **requieren una gran cantidad de datos** de entrada sobre variedades, manejo y condiciones del suelo que no están disponibles en muchas partes del mundo o **que cuando están disponibles son muy difíciles de calibrar** debido a una gran cantidad de parámetros inciertos ([Lobell & Burke 2010](#)). Los **modelos estadísticos**, en los que los datos históricos sobre los rendimientos de los cultivos y el clima se utilizan para calibrar **ecuaciones de regresión relativamente simples**, proporcionan una alternativa común a los modelos basados en procesos ([Lobell & Burke 2010](#)) y son los que utilizaremos en esta tesis. Las principales ventajas de los modelos estadísticos son su **limitada dependencia de los datos de calibración de campo** y su evaluación transparente de las **incertidumbres del modelo**.

Modelos de crecimiento polinómico o umbral

Para modelar las **respuestas no lineales** del rendimiento de los cultivos ante el cambio climático (i.e. estancamiento y relación con las variables ambientales) recientemente se están utilizando modelos estadísticos **aditivos lineales** con aproximaciones **polinómicas** (ver [Schlenker & Roberts 2009](#)) o discontinuos (modelos de **umbrales**; ver por ejemplo [Grassini et al. 2013](#)). Estas aproximaciones no logran capturar la **disminución en la tasa de cambio** relativo del rendimiento del cultivo (*relative growth rate*, $RGR = \ln(Y[t]/Y[t-1])$ donde $Y[t]$ representa el

rendimiento del cultivo, para tiempos sucesivos) **para sistemas de cultivo de alto rendimiento**, o fallan en explicar y modelar la **respuesta funcional** del cultivo mediante **mecanismos biológicos reales**. Como hemos mencionado anteriormente, la RGR solo podría ser constante durante períodos cortos de una o dos décadas, pero sería inviable a largo plazo cuando los rendimientos agrícolas alcanzan su techo del potencial de producción ([Ray et al. 2013](#)).

Aproximación propuesta en esta tesis

Modelo de crecimiento logístico

La inferencia de los procesos que generan la dinámica de rendimiento observada en los cultivos depende en gran medida de la **elección de modelos apropiados**. Para modelar el crecimiento del rendimiento del cultivo mediante una **forma funcional** podemos utilizar el enfoque de **mínimos cuadrados no lineales** ([Paine et al. 2012](#)). Por ejemplo, el conocido **modelo logístico** proporciona una descripción simple de un sistema usando **pocos parámetros biológicamente relevantes** ([Royama 1992](#), [Berryman 1999](#)). En igualdad de condiciones, estos modelos estadísticos mecanicistas son **más poderosos** que los anteriores, ya que **informan sobre los procesos subyacentes** que impulsan los patrones y es más probable que funcionen correctamente al **extrapolar** más allá de las condiciones observadas ([Bolker 2008](#)). Además, estos modelos dan cuenta de la esperada **desaceleración** de los rendimientos de los cultivos a medida que se acercan a su **techo potencial** de rendimiento, permiten **comparar cultivos con distinto rendimiento** y **representar su tendencia asintótica**.

El **modelo logístico** es la forma funcional más utilizada para representar sistemas **no lineales**, debido a su **flexibilidad, realismo, previsibilidad y generalidad**. Por ejemplo, en el estudio del crecimiento de

plantas, el uso de tales técnicas ha permitido una mejor comprensión de los **componentes de la RGR**, los costes de un crecimiento rápido y la relación con otros factores como plagas, malezas y patógenos ([Paine et al. 2012](#)). El modelo logístico tiene la ventaja de que los parámetros presentan una interpretación biológica directa, propiedades lógicas y una estructura parsimoniosa ([Royama 1992](#)).

Royama ([1992](#)) ha propuesto además una **extensión del modelo logístico tradicional** para dar cuenta de **factores externos de perturbación** sobre la tasa de crecimiento de un sistema. Estos modelos permiten evaluar los **efectos aditivos y no aditivos** de los factores exógenos (como el clima) sobre el rendimiento de los cultivos, y proponer mecanismos biológicos que lo expliquen. Un **efecto no aditivo** del clima o CO₂ sobre el rendimiento del cultivo modifica el potencial de rendimiento del cultivo, al impactar sobre la disponibilidad o los requerimientos de algún factor limitante o recurso, pero no modifican su estabilidad. Las condiciones ambientales ejercen efectos de perturbación **aditivos** sobre el cultivo cuando cambian su capacidad máxima de rendimiento ([Royama 1992](#)).

En la construcción de tales modelos la noción de **sistemas regulados juega un papel crucial**. Si además de existir una disminución en la tasa de cambio del rendimiento a medida que aumenta el rendimiento del cultivo, observamos que existe un punto de equilibrio dinámico, donde la tasa de cambio es nula ($RGR=0$), entonces se cumplirían las condiciones de **regulación del sistema** con las implicaciones discutidas en las páginas 15-16.

La nueva aproximación que proponemos nos permite centrarnos en nuevas propiedades estructurales tales como la **estabilidad** de la dinámica del rendimiento y detectar **respuestas no lineales del cultivo ante el cambio climático**. La estabilidad de un sistema está determinado, en gran medida, por su **estructura de retroalimentación**. La retroalimentación negativa tiende a controlar el sistema, o regularlo, y define la estructura de

equilibrio del sistema ([Berryman 1999](#)). Raramente se observa un sistema biológico en un equilibrio preciso, sino que observamos su tendencia a retornar hacia un estado particular luego de las perturbaciones externas. La mayoría de los problemas de dinámica del sistema **no son lineales**. Debido a que un cultivo no puede producir de manera ilimitada se producen patrones no lineales en el rendimiento del cultivo. Esto significa que las relaciones causa-efecto entre variables no son proporcionales. Los efectos no lineales pueden ser sutiles, porque un determinado efecto observado en un rango puede no ser válido en otro rango.

La idea es construir una estructura formal que pueda, por sí misma, reproducir las características esenciales del problema dinámico. La importancia de los **factores internos** no debe subestimarse, dicta aspectos de la formulación del modelo: las **perturbaciones externas** se ven como desencadenantes del comportamiento del sistema (como si desplazaran un péndulo), y las causas están contenidas dentro de la **estructura del propio sistema** (como la interacción del péndulo con la posición y el momento que produce las oscilaciones). Las respuestas compensatorias dependen de las condiciones dentro del sistema. Dividir las series temporales en **señales internas y externas** ofrece nuevos conocimientos sobre la dinámica de nuestros sistemas, permite a los científicos pensar más claramente sobre la dinámica de un sistema y explicar los patrones reales de la producción en la agricultura.

En el apéndice [A1](#) se discuten las similitudes y diferencias de los modelos propuestos en esta tesis, respecto a los modelos clásicos de series temporales.

Potencial máximo de rendimiento

Todo crecimiento debe eventualmente enfrentar algunos **límites** (área, alimento, agua, recurso, etc.). La capacidad máxima (a menudo llamada "**capacidad de carga**" en ecología) es una medida global de resumen

que representa varios de estos límites ([Royama 1992](#)), de modo que una región determinada no puede sostener más producción que esta capacidad. Dicho valor se puede estimar a través del **punto de equilibrio** de nuestro modelo.

En esta tesis proponemos que la capacidad máxima del sistema de cultivo podría representar **el potencial máximo del rendimiento del cultivo**, o el rendimiento en el **equilibrio**. Esto sería especialmente útil para **realizar estimaciones** de cultivos para los cuales aún no se han desarrollado modelos fisiológicos o mecánicos. Además, los modelos estadísticos son **fáciles** de calibrar/ajustar, a diferencia de los fisiológicos, que necesitan un gran número de parámetros, y nos permitirían cuantificar fácilmente la **incertidumbre** utilizando técnicas estadísticas estándar como el remuestreo o bootstrap o el coeficiente de determinación. Esta estimación sencilla del potencial de rendimiento nos permitiría realizar evaluaciones sobre la **sostenibilidad regional y la planificación** directa de medidas de adaptación y desarrollo.

1.4 Objetivos

El propósito de esta contribución es lograr una **comprensión más profunda y realista sobre los procesos agroecológicos que determinan la dinámica del rendimiento de los cultivos para hacer frente a los impactos del cambio climático**. A partir de esta comprensión podremos proponer **medidas de manejo eficientes para aumentar el rendimiento de los cultivos y su estabilidad**.

Como **objetivos específicos** nos hemos planteado:

- Determinar la **estructura interna** que causa los patrones dinámicos y la estabilidad observada en los rendimientos de los cultivos cerealistas. Esto implica analizar cómo y cuánto varía la

tasa de cambio del rendimiento (RGR) para los principales cultivos. Analizar si existe un **patrón general** o si existen diferencias entre cultivos en esta tasa, comparando distintas regiones agrícolas. Si existen diferencias, determinar a qué se deben. Evaluar si la dinámica del rendimiento de los cultivos de cereales está **regulada** y cómo (detectar los posibles **mecanismos de regulación**).

- Determinar cómo los **factores externos (bióticos y abióticos)**, y su interacción, perturban el rendimiento de los cultivos cerealistas a diferentes escalas espaciales. Determinar qué tan importantes son los cambios climáticos y otros factores externos (ej. CO₂ y malezas) en la perturbación del rendimiento de los cultivos y mapearlo. Evaluar distintos **mecanismos** por los cuales actúan, en particular, diferenciar las respuestas **aditivas o no aditivas (multiplicativas) del cultivo**. Explicar sus **consecuencias dinámicas** (e.g. respuestas de tipo umbral y no lineal).
- Analizar las consecuencias dinámicas de la interacción entre factores internos y externos: la **estabilidad** del rendimiento del cultivo y su **potencial máximo** de rendimiento. **Detectar cultivos y regiones vulnerables al cambio climático**, en países en desarrollo en Sudamérica y en países clasificados como “hot-spots” por los pronósticos de calentamiento y crisis hídrica, como España. Analizar qué cultivos y regiones ofrecen más esperanza para alcanzar las demandas proyectadas, y dónde se necesitan medidas de **adaptación y mitigación** ante el cambio climático.
- Evaluar la **pérdida de rendimiento debida al estrés hídrico**. Evaluar espacialmente los **patrones y causas** de este déficit hídrico. Determinar si la diferencia en el rendimiento de los cultivos de secano/regadío se debe a un **cambio en la estructura** endógena del sistema y/o a los **efectos de perturbación** externos

del clima. Analizar el efecto del **riego del cultivo**, y evaluarla como medida de **adaptación y mitigación** ante el cambio climático, en qué situaciones y cómo.

- Evaluar el **efecto de la biodiversidad del ecosistema agrícola** sobre el rendimiento del cultivo. En particular vamos a evaluar el **efecto de la diversidad de la comunidad de malezas** sobre el rendimiento el cultivo ante el cambio climático en un experimento a largo plazo realizado en Michigan-EE.UU. Analizarla como herramienta de **adaptación y mitigación** ante el cambio climático, en qué situaciones y cómo.

En la siguiente tabla se indican los objetivos que serán abordados en cada artículo presentado en esta tesis.

	Artículo 1. Ocho cereales en Sudamérica	Artículo 2. Limitaciónes hídricas del maíz en España	Artículo 3. Efecto de la diversidad de malezas en un LTER Michigan-EE.UU.
Determinar la estructura interna que causa los patrones dinámicos observados en el rendimiento de los cultivos cerealistas y los mecanismos que la determinan. Evaluar si son sistemas regulados . Cuantificar y mapear su contribución relativa. Analizar sus consecuencias.	✓	✓	✓

Determinar cuáles factores externos perturban el rendimiento de los cultivos (cambio climático y nivel de CO ₂ , diversidad de malezas) y cómo lo hacen (respuestas aditivas vs no aditivas). Cuantificar y mapear su contribución relativa. Analizar sus consecuencias.	✓	✓	✓
Estimar la estabilidad y potencial del rendimiento de los cultivos por región y analizar sus diferencias. Detectar zonas donde los cultivos de cereales son vulnerables al cambio climático, en: <ul style="list-style-type: none"> • Sudamérica y • España. Proponer medidas de adaptación y mitigación para los sistemas agrícolas ante el cambio climático.	✓	✓	
Calcular la pérdida de rendimiento debida a estrés hídrico y los factores climáticos que la afectan. Proponer medidas de adaptación y mitigación para los sistemas agrícolas ante el cambio climático.		✓	
Evaluar el efecto de la diversidad de la comunidad de malezas sobre el rendimiento de los cultivos, y su interacción con el cambio climático. Proponer medidas de adaptación y mitigación para los sistemas agrícolas ante el cambio climático.			✓

Capítulo 2

2. Cambio climático y agricultura de cereales en el sur de Sudamérica: impactos y adaptación

2.1 Introducción

Analizamos **8 cultivos** (trigo, maíz, arroz, soja, avena, cebada, sorgo, girasol) en el **sur de Sudamérica**, una de las regiones más productivas del mundo y que se espera juegue un rol cada vez más importante en la producción de alimentos a nivel mundial ([World Bank 2018](#)). La región tiene un gran potencial para el aumento de la producción agrícola mediante el cierre de las brechas de rendimiento existentes, presenta el 30% los recursos renovables de agua dulce del mundo y una gran biodiversidad. La mayoría de los países de Sudamérica son exportadores netos de alimentos. Argentina, Brasil y Uruguay se han especializado en la producción de cultivos anuales, representan el 7% de la producción global de cereales y han triplicado el área plantada para soja en la última década. Por otro lado, la región está siendo afectada por el cambio climático que prolonga e intensifica el impacto de eventos cíclicos como las sequías e inundaciones provocadas por el ENSO (El Niño-Southern Oscillation; [Porter et al. 2014](#)).

En este capítulo evaluamos la existencia de **características comunes** en las dinámicas del rendimiento de los principales cultivos de cereales que nos permitan entender los **procesos subyacentes**. Proponemos además modelos capaces de diferenciar distintos tipos de **respuestas** (**aditivas y no**

aditivas, según [Royama 1992](#)) del cultivo ante los cambios en las condiciones climáticas y el nivel de CO₂ atmosférico durante su período de crecimiento. Identificamos zonas agrícolas donde los impactos climáticos han sido **críticos** y sus implicaciones para el **manejo de los cultivos**.

El capítulo contiene el artículo “*Crop Production Structure and Stability under Climate change in southern South America*” publicado en la revista *Annals of Applied Biology* (Q1) (ver pag. 4). El material complementario de este artículo se encuentra disponible en el apéndice.

2.2 Crop production structure and stability under climate change in South America

Annals of Applied Biology ISSN 0003-4746

RESEARCH ARTICLE

Crop production structure and stability under climate change in South America

R. Ferrero^{1,2,3}, M. Lima^{2,3,4} & J.L. Gonzalez-Andujar^{1,3}

¹ Departamento Protección de Cultivos, Instituto de Agricultura Sostenible, Consejo Superior de Investigaciones Científicas (CSIC), Córdoba, Spain

² Center of Applied Ecology & Sustainability (CAPEs), Pontificia Universidad Católica de Chile, Santiago, Chile

³ Laboratorio Internacional de Cambio Global, LINGG (CSIC-PUC), Santiago, Chile

⁴ Departamento de Ecología, Pontificia Universidad Católica de Chile, Santiago, Chile

Keywords

Crop management; food production; negative feedback; nonlinearity; regional dynamics models; time series.

Correspondence

Rosana Ferrero, Departamento Protección de Cultivos, Instituto de Agricultura Sostenible (IAS), Consejo Superior de Investigaciones Científicas (CSIC), Alameda del Obispo, s/n Apdo. 4084, 14080 Córdoba, Spain. Email: rferrero@ias.csic.es

Received: 7 May 2016; revised version accepted: 4 September 2017.

doi:10.1111/aab.12402

Abstract

Southern South America is expected to play an increasingly important role in global food production, but climate change could seriously threaten it. Here we have analysed long-term historical data for major crops (rice, oats, barley, sunflower, soybean, sorghum, wheat, maize) at subnational scale to (a) look for common features among crop yield dynamics, evaluating their structure and implications for the persistence of that crop; (b) address complex crop responses to changes in environmental growing conditions; and (c) identify climate impact hotspots that are crucial for adaptation and mitigation. We have proposed a novel methodological approach based on dynamics systems in order to understand the processes behind annual crop yield fluctuations. We report the results of general patterns in the internal process (biophysical adjustments by rapid negative feedbacks) regulating crop production and analyse how it influences crop persistence and yield ceilings. The structure of a crop yield dynamic system defines its behaviour, but climate variations could displace it from yield equilibrium and affect its stability. Our findings suggest that weather conditions have a stronger impact on yield growth at high rather than at low yield levels (non-additive impacts). This allows agriculture management to be refined and applied more efficiently, weakening the relationship between crop productivity and climate change and predicting the response of crop production to yield-improvement strategies. We have identified those crops and regions which are most vulnerable to the current climate change trends in southern South American agroecosystems. Our results allow us to point to new ways to enhance self-regulatory success, maximising the efficiency of crop production and reducing climate impacts. We have discussed important implications for crop management and climate change mitigation in an area where agriculture plays a key role in its socioeconomic and ecologic dimensions.

Introduction

Global food demand is increasing rapidly. Ensuring food production in a growing population and the changing climate pose a major challenge to scientists, resource managers and policymakers (Alexandratos & Bruinsma, 2012; Porter *et al.*, 2014). Changes in temperature, precipitation and CO₂ emissions are expected to have net negative effects on global agriculture, particularly in developing countries (IPCC, 2014). Southern South

America is expected to play an increasingly important role in global food production because of the region's ability to produce and export agricultural commodities, its potential of new arable land and its share of renewable water resources (Magrin *et al.*, 2014). However, the most relevant studies in the region are limited to a few crops in La Pampa (Magrin *et al.*, 2005 – wheat, maize, sunflower, soybean; Asseng *et al.*, 2013 – wheat; Verón *et al.*, 2015 – maize, wheat, soybean). No studies have

so far evaluated the effects of climate change across a large series of crops and subregions in southern South America. Also, there are several examples of discordance between the results of crop yield studies in the region that makes it difficult to identify common patterns of vulnerability to climate change (e.g. for wheat, Verón *et al.* (2015) detected mainly a negative impact of temperature on crop yield, whereas Magrin *et al.* (2005) and Asseng *et al.* (2013) identified a positive effect of rainfall). Therefore the objectives of our research were to (a) look for common features among several crop yield dynamics evaluating their structure and implications for the persistence of that crop; (b) address complex crop responses to changes in growing conditions; (c) identify climate impact hotspots at subnational scale that are crucial for decision-making on adaptation and mitigation.

The structure of a dynamics system has a defining influence on its behaviour (Berryman, 1989). An increasingly common approach to studying crop yield dynamics is the use of statistical models to evaluate the response of yields to climate changes (Lobell & Field, 2007; Lobell *et al.*, 2011). These models can be applied extensively because they require low detailed input data, have a low uncertainty and are more suitable for larger spatio-temporal scales (Lobell & Burke, 2010; Shi *et al.*, 2013). However, the models usually make the implicit (and in an extreme case, unrealistic) assumption that crop yield dynamics is governed by the weather and independent of the yield level (i.e. the same quantity of yield is added in each unit of time) and then crop yield growth could continue indefinitely. This assumption could only be appropriate for modelling systems beyond the maximum potential crop yield, which is not usually the case for most crops and regions. We all know that the upper limit of crop production is set by the climate conditions and the genetic potential of the crop (e.g. Doorenbos & Kassam, 1979), and therefore we have to explicitly include it in our crop statistical models. It can be seen as a random walk process with a distribution that becomes wider with time (i.e. its variance is unbounded and there is no correlation in time; Royama, 1992). However, empirical evidence shows that historical crop yield dynamics has been fairly stable and fluctuates around a trend (or around its persistent state if there is no trend) but does not deviate or drift unboundedly away from it (Lin & Huybers, 2012; Grassini *et al.*, 2013). Recent reports have also indicated the necessity of recognising biophysical limits to crop yield in order to account crop yield growth and stagnation (Ray *et al.*, 2012; Grassini *et al.*, 2013). Individual physiology or height-structured competition for light affect the conversion of those resources into biomass (Purves & Pacala, 2008), so that crop yield growth rate is usually lower for high yield values, although traditional statistical

models assume that it is constant. Here we propose that the best way to accommodate temporal variations in crop growth rates is with nonlinear growth models. Specifically, we propose the logistic model as the functional form for crop yield growth analysis because of its flexibility, realism, predictability and generality. Stable and stagnant crop yield changes could be the consequence of a negative feedback structure (due to biophysical internal processes), able to persist over time in a state of dynamics equilibrium with their environment (Ferrero *et al.*, 2014, 2017). Understanding and modelling how both feedback mechanisms and climate interact in shaping the dynamics of crop yield may be fundamental to our ability to predict crop response under climate change.

Climate and CO₂ emissions may have complex effects on crop yield rates. The reliability of our predictions and mechanistic understanding of crop yield dynamics are influenced by whether additive or non-additive approaches are made (see, e.g. Schlenker & Roberts, 2009). However, the interactive (non-additive) effects of climate and crop yield have usually been ignored, or are modelled with polynomial functions of climate, independent of yield level, which are very difficult to interpret (e.g. Schlenker & Roberts, 2009; Lobell & Burke, 2010; Lobell *et al.*, 2011). Again, we suggest that the response of the crop to climate variations may not be independent of its yield level because – for example – a crop usually does not respond in the same way to water availability at high yield (high biomass) as when it is at low yield levels (low biomass; e.g. the milestone publication of Doorenbos & Kassam (1979) and our recent study, Ferrero *et al.* (2014)). Generally, when the crop has a higher yield, it also has a greater water demand and, therefore, we over-estimate the response of the crop to climate change if we do not consider it, at least for high-yield systems. Recently, we used models with biologically interpretable parameters, that also take into account the nonlinear crop yield growth previously discussed, to understand hydric stress in maize throughout Spain (Ferrero *et al.*, 2014), and the effects of weed community diversity and climate on maize and soybean in a long-term experiment in Michigan, USA (Ferrero *et al.*, 2017). Here we consider whether general patterns exist for a more profound understanding of crop yield dynamics in order to develop wide-ranging strategies for coping with the impacts caused by climate change.

In this study, we have hypothesised the existence of biophysical processes (negative feedback structure) regulating crop yield fluctuations and the non-additive interactions between environmental factors and crop yield levels. We analysed eight strategic crops at subnational scale in southern South America: oats (*Avena sativa* L.), barley (*Hordeum vulgare* L.), sorghum (*Sorghum* spp.), rice

(*Oryza sativa* L.), wheat (*Triticum aestivum* L.), maize (*Zea mays* L.), sunflower (*Helianthus annuus* L.) and soybean (*Glycine max* Merr.). More specifically, statistical models combining internal (feedback structure) and external (climate; CO₂) processes and long-term historical data (20–50 years) have been used in order to understand crop yield persistence and its role in determining crop yield responses to climate change impacts. We identified those crops and regions that are most vulnerable to the actual climate change trends in South American agroecosystems. Our study could have important implications for management of crops and climate change mitigation, especially, in an area where agriculture plays a key role in its socioeconomic and ecologic dimensions.

Materials and methods

Study site and focal crop yields

Historical yield data or the mass harvested per unit area (kg ha⁻¹) for Argentina (1969/70–2010/11), Uruguay (1960/61–2010/11), Chile (1979/80–2010/11) and Brazil (at least 19 years; see Fig. S1 in Appendix S1, Supporting Information, for details on regions) were obtained from their respective statistical yearbooks. We used Global Historical Climatology Network data on monthly temperature and rainfall (mean, minimum, maximum and extreme; Lawrimore et al., 2011). For sites with missing data (Valparaíso, Santiago, Chillán, Valdivia), we obtained Chile's weather annuals in climatologic yearbooks.

Climate and CO₂-related variables

Climate-related variables in the crop growing season were considered to be determinant drivers of yield crop fluctuations. Here, we considered average temperature, the maximum and minimum temperature and the total rainfall for this period. In addition to modelling the general (average) effects of climate on crop yield, we included the effects of extreme temperature or precipitation events in the growing season, which may have disproportionately large impacts on final yields. The growing seasons selected for the different crops were rice (November–February), oats (March–December), barley (March–December), sunflower (October–February), maize (October–May), wheat (June–November), sorghum (November–April) and soybean (November–May). Additionally, also considered was the annual effect of carbon dioxide (CO₂), an important atmospheric gas that contributes to global warming. The country's data on the emissions of CO₂ (kt) were taken from the World Bank's World Development Indicators (World Bank, 2012) as a proxy of CO₂ in the atmosphere.

Diagnosis and statistical models of yield dynamics

To remove any trends on crop yield, we used detrending (i.e. rotating the series around the linear or quadratic trend). We defined the annual rate of yield increases as the first-differences of log-yield $R_t = Y_t - Y_{t-1}$, where Y_t is the detrended log-yield at time t (log transformation transforms absolute differences to relative differences and allows reduced heteroscedasticity) and Y_{t-1} is the same series with 1 year of delay (lags 1). We built a first model that included the effects of internal processes on R_t without any exogenous perturbation. In order to do that we used the generalised exponential form of the discrete logistic model (Ricker, 1954; pure *endogenous* model),

$$R_t = r_{\max} - \exp(a \cdot Y_{t-d} + c) \quad (1)$$

where Y represents the log-yield data at time t , d is number of time lags to be included in the model, r_{\max} is a positive constant representing the maximum productive rate observed and c and a are parameters. We used the partial rate correlation function (PRCF; Royama, 1977) to determine how many time lags (d) should be included in the model (1).

Eqn 1 was modified to represent additive and non-additive crop responses to environmental perturbations (external processes; e.g. temperature effects). Additive perturbations were considered through the inclusion of the Z_t term,

$$R_t = r_{\max} - \exp(a \cdot Y_{t-d} + c) + b \cdot Z_{t-d'} \quad (2)$$

where Z_t is the environmental perturbations (e.g. precipitation), d' denotes the number of lags to be included in the model (with $d' = 0$ and 1) and b is a parameter. Environmental conditions exert additive perturbation effects on the annual rate of yield increases through changes in r_{\max} (vertical effect, *sensu* Royama, 1992; Text S1 in Appendix S2). Both equilibrium point and the speed at which the system approaches equilibrium could be altered.

Changes in c (Eqn 1), involve the non-additive interactive effects of climate or CO₂ and crop yield levels (*lateral* effect, *sensu* Royama, 1992),

$$R_t = r_{\max} - \exp(a \cdot Y_{t-d} + c + b \cdot Z_{t-d'}) \quad (3)$$

Here the environmental perturbations affect the yield potential but not its stability.

Finally, environmental perturbations may have a non-additive influence on yield dynamics as the parameter a changes (Eqn 1; *nonlinear* effect, *sensu* Royama, 1992),

$$R_t = r_{\max} - \exp((a + b \cdot Z_{t-d'}) \cdot Y_{t-d} + c) \quad (4)$$

In this last case, both the equilibrium point and the speed at which the system approaches equilibrium could change.

Model fitting and model selection

We fitted Eqns 1–4 using nonlinear least squares regressions with the *nls* library in the software *R* (R Development Core Team, 2011). In particular, the models were fitted by minimising the Akaike criterion (AIC; Sakamoto *et al.*, 1986), and maximising pseudo R^2 measures based on the residual deviance (Cameron & Windmeijer, 1996). Models were chosen on the basis of their goodness-of-fit, their ability to describe the correct dynamics and their appropriateness.

Results

Biophysical internal processes

Between 26% and 83% of the variance in annual rates of yield increase was explained by biophysical internal processes (i.e. first-order-negative feedback processes) in major crops and regions in South America (see pure *endogenous* model in Table S1 and Fig. S2 in Appendix S1). All crops presented a stabilising negative feedback structure and, therefore, self-regulation in their dynamics.

Additive and non-additive climate and CO₂ effects

Several models selected for evaluating climate change impacts on crop yield alterations between regions explained the additional 4%–33% of their variance (Fig. 1; Table S1 and Fig. S3 in Appendix S1). We found that the interaction between climate variables or CO₂ emission and crop yield level (non-additive effects) were more common than an independent perturbation of crop yield (additive effects; Table S1 in Appendix S1).

Several patterns emerge from these models. For some crops, such as maize, oat, barley and sunflower, annual crop growth rates were affected mainly by temperature (Fig. 1; Fig. S3 in Appendix S1). We found that oat yield dynamics was explained best by maximum temperature, with negative and non-additive effects in Paraná (Brazil) and Araucanía (Chile) but with positive responses (additive and non-additive) in Uruguay (Fig. 1B). In southern Brazil (Rio Grande do Sul) and Uruguay, extreme temperature influenced annual barley yield growth rate additively, but further west in Chile (Araucanía and Los Lagos; Fig. 1A) we found non-additive responses. For sunflower, non-additive effects of maximum temperature were also found in Uruguay and La Pampa (Argentina), but in the former it improved annual yield growth rates and in the latter its effect was negative. Minimum temperature affected sunflower yield variations through negative and non-additive responses in Entre Ríos (Argentina; Fig. S3 in Appendix S1). In Córdoba, Buenos Aires and Santa

Fé (Argentina), we found that maize yield variability was explained best by negative impacts of high temperatures, and more so at high-yield years (non-additive, Fig. S3 in Appendix S1), whereas minimum temperatures had positive and additive effects on maize production in Uruguay.

For soybean, sorghum and wheat, the results were more variable (see Fig. S3 in Appendix S1). While in the central region of Argentina (Córdoba and Santa Fé) temperature variability was more important for soybean yield fluctuations, in the east of South America precipitation and CO₂ emissions were more important (in Paraná (Brazil) and Uruguay, respectively). Sorghum annual yield growth rate was negative and non-additively affected by maximum temperatures in central regions of Argentina (Córdoba, Entre Ríos, Santa Fé, Santiago del Estero and Buenos Aires) and positively by rainfall in Minas Gerais (Brazil). Finally, the influence of temperature on wheat yield growth was statistically significant and positive in Santa Fé (Argentina) and Paraná (Brazil), but negative in Buenos Aires (Argentina), Uruguay and Bío Bío (Chile). Also for wheat, we detected the effects of rainfall in Rio Grande do Sul (Brazil) and CO₂ emissions in Córdoba (Argentina).

Finally, we determined that rainfall affected rice production through non-additive effects in Uruguay and Corrientes (Argentina), but in Maule and Bío Bío (Chile) minimum temperature was a better explanation of rice yield variability (Fig. S3 in Appendix S1).

Discussion

Crop yield dynamics is a key aspect for food security under climate change (Grassini *et al.*, 2013), mainly in South America where special emphasis is given to its role for global food production and environmental sustainability. Understanding crop yield interannual variability will enable us to improve it and to diminish the adverse impacts of agriculture for social and ecological systems. Here we analysed the effects of internal and external processes on the main crops (maize, soybean, wheat, rice, barley, oat, sunflower and sorghum) and producing countries (Argentina, Chile, south Brazil and Uruguay) of the region between 1960 and 2011. We found common features among crop yield dynamics due to growth constraints, complex crop responses to climate changes and hotspots that are crucial for adaptation and mitigation.

Biophysical internal processes have an influence on crop yield dynamics

We found that all crops studied across most regions of South America showed regulation by biophysical internal processes as the main drive of crop yield dynamics

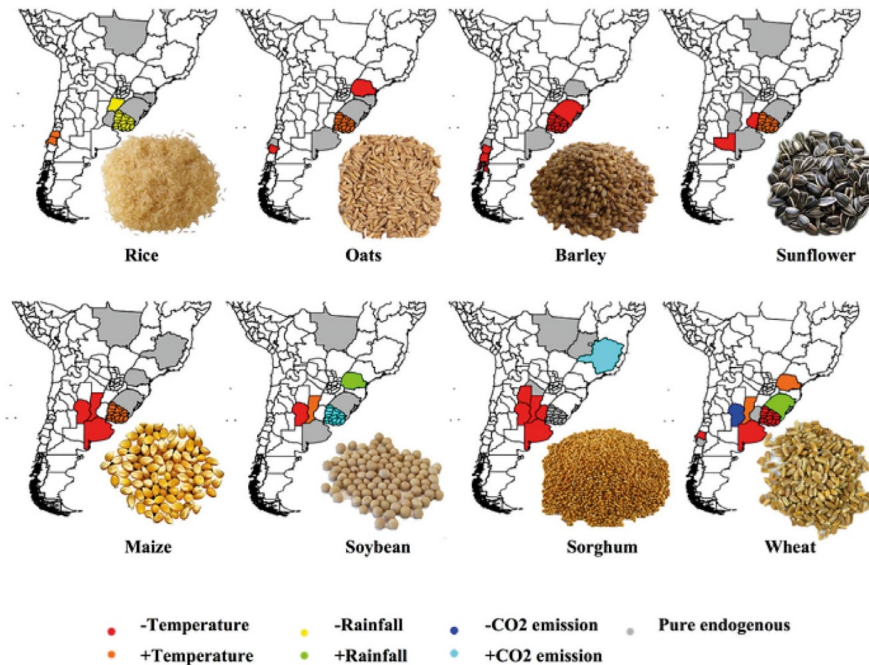


Figure 1 Annual crop yield growth rate responses to mean maximum temperature (MMXT, °C) for (A) barley in Los Lagos (Chile) with non-additive impacts and (B) oats in Uruguay with additive impacts. We divided each plot according to quartiles of MMXT (different colours), where shaded area shows confidence bands. See Table S1 in Appendix S1 for description of other models for temperature, precipitation and carbon dioxide emission effects on eight strategic crops in South America.

and its temporal persistence (Table S1 in Appendix S1). Our results suggest a general pattern of internal regulation on crop systems, which explained the essential features of the dynamics observed: high frequency, stable fluctuations and a dynamics equilibrium (its yield potential in the regions where the crop is produced). Regulation tends to produce stability by damping the effects of any changes in the environment (in other words, it does not follow a random walk). This is a non-trivial result for management purposes because such a regulatory mechanism may influence potential declines or recovery in crop yield. Our results are consistent with the recent evidence of stabilisation, stagnation and the hypothesis of a biophysical yield ceiling (Ray *et al.*, 2012; Grassini *et al.*, 2013). Nevertheless, unlike these studies, here we did not use threshold models, but we modelled internal limitations on annual crop yield growth rates that produce bounded

variations and autocorrelation between time steps. Our findings suggest that regulation structure by biophysical limits could improve our understanding and prediction of climate change problems.

Environmental external processes have additive and non-additive impacts on crop yield dynamics

We assessed additive and non-additive crop responses to climate change in historical time series models and evaluated changes in the yield potential and its stability due to these perturbations (Fig. 1; Table S1 and Fig. S3 in Appendix S1). A novel aspect of the observed crop yield dynamics is the fact that non-additive climatic effects (the effect of the interaction between climate and crop yield level) are much more common than the additive ones (an independent effect of climate on crop yield level). Here we

modelled explicitly the interactive (non-additive) effects of climate and crop yield, unlike previous studies that use polynomial regression or threshold levels – difficult to interpret – to account for nonlinear climate effects on crop yield (Schlenker & Roberts, 2009; Lobell *et al.*, 2011). Our results suggest that climate impacts are particularly harmful at high yield levels, when crops demand more nutrients but the availability of resources decreases or remains constant. As a result of non-additive climatic effects, small changes in a climate factor could exert big ones in the average yield but would not perturb the stability of equilibrium. This general finding on crop yield dynamics is crucial to crop yield forecasting and for management purposes, because ignoring it could lead to oversized predictions about mitigation tools under climate change by implying that these tools are equally effective at low and high crop yield levels. Finally, it is important to highlight that because all crops are basically systems defined at high yield levels, it is essential to model and predict the problems that generate non-additive climate effects.

Regional summaries: which crops in which geographic regions are most threatened

A few studies have explicitly compared climate impact for different regions or crops to identify areas at most risk (Porter *et al.*, 2014). Here we found that the effect of climate variability on crop yield was evident in several regions of southern South America and for most crops. Negative impacts of climate variability have been more common than positive ones. Also, we detected the great sensitivity of crop yields to extreme temperatures unlike most studies in the region, which highlight the role of rainfall (e.g. Magrín *et al.*, 2005; Asseng *et al.*, 2013) but in concordance with a recent study in the Pampas (Verón *et al.*, 2015) and with the global trend (Abrol & Ingram, 1996; Lobell & Field, 2007; Lobell *et al.*, 2012; IPCC, 2014; Fig. 2). Differences in the methodology used may explain this disagreement because – unlike our analysis – the first studies used crop simulation models that tended to over-estimate rainfall importance (Maltais-Landry & Lobell, 2012). Specifically, temperature was the only variable explaining oat, barley, sunflower and maize performance, mostly in a negative and non-additive way. These facts imply that warmer conditions mainly affected crops at high yield levels, probably due to low nutrient intake under high temperature levels (Abrol & Ingram, 1996) or by increased water stress (Lobell *et al.*, 2013), decreasing the yield equilibrium for most of the crops studied. However, positive temperature effects were mainly found in the south east of the region: Uruguay (oat, sunflower and maize), Santa Fé (soybean and wheat) and Paraná

(soybean and wheat), where water does not appear to be a limiting factor (Magrín *et al.*, 2014). Specifically, positive and non-additive effects on temperature were the important factor for yield growth rate in oat, sunflower and maize in Uruguay, soybean in Paraná (Brazil), wheat in Córdoba (Argentina) and rice in Maule and Bío Bío (Chile). For example, it has been suggested that warming may prevent the stress of low minimum temperatures at high latitudes like in Chilean rice crops, because freezing may decrease the absorption of water and mineral nutrients (Yoshida, 1981; Zia *et al.*, 1994) or reduce plant growth and leaf elongation rates (Sowiński *et al.*, 2005). The existence of both patterns is not surprising, because the relationship between crop yield growth and temperature could be visualised as a hump-shaped curve. Crop yield growth is slow at the lower and upper ends of a given temperature range, and highest at some optimal point. The optimal temperature varies for each crop and depends on its physiology. Therefore, we might find both positive and negative outcomes under different temperature values.

In Corrientes (Argentina) and Uruguay, though rice is irrigated, rainfall was a major problem due to El Niño/Southern Oscillation (ENSO) events of high rainfall (see Magrín *et al.*, 2014). Here we detected that rainfall affected rice production through non-additive effects maybe because of lesser solar radiation in years of high rainfall, with more negative impacts in high-yield years. As these regions are important rice producers in South America, our results suggest that using climate forecasting to reduce production risks should consider non-additive consequences on rainfall regimes, due to ENSO events.

Elevated CO₂ is expected to have impacts on crop yield (Ainsworth *et al.*, 2002). Our results showed that CO₂ emission exhibited both positive and negative effects on soybean (Uruguay) and wheat (Córdoba, Argentina) crops, respectively, mostly through additive effects (Fig. 2). Positive responses of increased CO₂ emissions on grain yield are in agreement with previous studies, which postulated that the primary effect of plant response to rising atmospheric CO₂ is to increase yield (Ainsworth *et al.*, 2002). However, wheat responded negatively to CO₂, probably due to the interactions of CO₂ with high temperatures, water status or low nitrogen fertiliser availability (Lawlor & Mitchell, 2000). Consistent with previous research, C3 species such as wheat and soybean are expected to respond more strongly than C4 crops. Regional CO₂ effects are not often considered (but see McGrath & Lobell, 2013), but our results suggest that yield response to increased CO₂ will vary between regions due to interactions with other environmental variables. Further research should include these interactions in statistical models to fully understand potential impacts

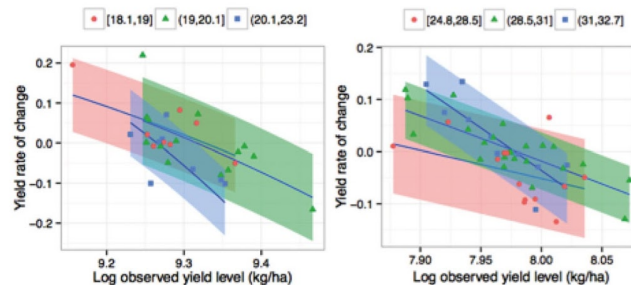


Figure 2 Estimated net impact of temperature, rainfall and CO₂ emission on eight major crop productions in South America in addition to internal processes (e.g. pure endogenous model). We report the most relevant external driver for each crop and region, as detected by the fitting of the models (see Table S1 in Appendix S1).

of CO₂ on food production. For example, the benefit for soybean would not be so promising, because it has been suggested that, under future climate change conditions, the interactive effects of elevated CO₂ and warmer temperatures are not likely to benefit soybean growth (McGrath & Lobell, 2013). As soybean and wheat are main crops in South America, our model could be the benchmark from which to evaluate future CO₂ changes and their interaction with climate-related variables.

Some caution should be exercised in interpreting these results. Here our models explain a high variability with respect to previous statistical models (e.g. Verón *et al.*, 2015; 30%–47%) probably because we considered particular temperature or precipitation events which could have pronounced effects on yield. For example, in specific locations, we accounted for more than 80% of the variability in a crop's yield. The variance percentages not explained by these statistical models could be due to technological factors, soil conditions and/or climate on a lower local scale than the regional one. Also, the accuracy of statistical models is dependent on the spatial scale (at more local scales, the role of precipitation may be more important than temperature; Porter *et al.*, 2014) and the reliability of input data (yield or weather measurements; e.g. Sadras *et al.*, 2014). We detected that crop yield dynamics were controlled by simple feedback structures, and therefore, only one feedback dominated its dynamics close to equilibrium (Berryman, 1999). However, this could change in the future given some external or internal factors, and it may be possible to find complex regulatory structures and alternative stable states if the climate keeps changing. Moreover, although our models have the advantage of the parameters having a direct biological interpretation, a parsimonious structure and more flexibility (Royama, 1992), nonlinear model forms often

ensure, but not guarantee, proper extrapolation. This is particularly important for soybeans and wheat, where positive effects of recent climate variability in the region have been detected, but the results should be projected carefully because more complex dynamics can emerge and more warming might slow yield gains as in global wheat production (Asseng *et al.*, 2015). In addition, it should be noted that our study used CO₂ national levels to estimate the effect of elevated CO₂ on crop yields so that we could be underestimating this effect. Local measurements are needed in the future to achieve more accurate models on the effect of CO₂. Finally, while our study revealed new and interesting findings, follow-up studies should examine the interactions between different aspects of climate change to improve our adaptation options in agriculture.

Conclusions

We have shown the existence of general patterns for the major crop yield dynamics in South America based on the interactions between internal (biophysical limits by first-order-negative feedback) and external (climate and CO₂ emission) factors. These results show crop yield as a regulated process unlike a random walk as presented previously. Statistical models for crops need to account for the universal trade-off between yield growth rate and yield levels, and here we have proposed a flexible model with nonlinear functions and biological meaning that does not include artificial breakpoints. We have identified those crops and regions that are most vulnerable to climate change in South America. We have also recognised that distinguishing the effects of both additive and non-additive climate impacts will help us to identify the mechanisms that influence the response

of agroecosystems to environmental change. We suggest that projections of crop yield models based on extension of historical trends of the past decades should be viewed with caution because we must consider the crop yield level (i.e. its status) in both the deceleration of its rate of increase (due to biophysical limits) and in its interaction with climate change (by non-additive responses). Our findings may be crucial to predicting the response of crop to yield-improvement strategies and may have important implications for management and adaptation measures for crop systems and climate change mitigation. Finally, we strongly suggest the importance of theoretical dynamic models based on biological knowledge for understanding the interaction between regulation structure and environmental factors in shaping the dynamics of crop yields. This allows us a deeper understanding of ecological processes than was possible with traditional approaches. The methods we develop are general and can be applied to a wide range of crops.

Acknowledgements

R. F. gratefully acknowledges receipt of a grant from the Fundación Carolina. J. L. G-A and R. F. were supported by FEDER (European Regional Development Funds) and the Spanish Ministry of Economy and Competitiveness funds (AGL2012-33736). R. F. and M. L. acknowledge financial support from Center of Applied Ecology and Sustainability (CAPES; CONICYT FB 0002-2014). The authors are grateful to Laboratorio Internacional en Cambio Global (LINCGlobal) for their support.

References

- Abrol Y.P., Ingram K.T. (1996) Effects of higher day and night temperatures on growth and yields of some crop plants. In *Global Climate Change and Agricultural Production. Direct and Indirect Effects of Changing Hydrological, Pedological and Plant Physiological Processes*, pp. 124–140. Eds Fakhri Bazzaz and Wim Sombroek. Rome, Italy: Wiley and FAO, United Nations.
- Ainsworth E.A., Davey P.A., Bernacchi C.J., Dermody O.C., Heaton E.A., Moore D.J., Morgan P.B., Naidu S.L., Yoo Ra H., Zhu X., Curtis P.S., Long S.P. (2002) A meta-analysis of elevated [CO₂] effects on soybean (*Glycine max*) physiology, growth and yield. *Global Change Biology*, **8**, 695–709.
- Alexandratos N., Bruinsma J. (2012) World agriculture towards 2030/2050: the 2012 revision. *ESA Working Paper*, No. 12-03. Rome, Italy: Food and Agriculture Organization of the United Nations.
- Asseng S., Travasso M.L., Ludwig F., Magrin G.O. (2013) Has climate change opened new opportunities for wheat cropping in Argentina? *Climatic Change*, **117**, 181–196.
- Asseng S., Ewert F., Martre P., Rötter R.P., Lobell D.B., Cammarano D., Kimball B.A., Ottman M.J., Wall G.W., White J.W., Reynolds M.P., Alderman P.D., Prasad P.V.V., Aggarwal P.K., Anothai J., Basso B., Biernath C., Challinor A.J., De Sanctis G., Doltra J., Fereres E., Garcia-Vila M., Gayler S., Hoogenboom G., Hunt L.A., Izaurralde R.C., Jabloun M., Jones C.D., Kersebaum K.C., Koehler A.-K., Müller C., Naresh Kumar S., Nendel C., O'Leary G., Olesen J.E., Palosuo T., Priesack E., Eyshi Rezaei E., Ruane A.C., Semenov M.A., Shcherbak I., Stöckle C., Stratonovitch P., Streck T., Supit I., Tao F., Thorburn P.J., Waha K., Wang E., Wallach D., Wolf J., Zhao Z., Zhu Y. (2015) Rising temperatures reduce global wheat production. *Nature Climate Change*, **5**, 143–147.
- Berryman A.A. (1989) The conceptual foundations of ecological dynamics. *Bulletin of the Ecological Society of America*, **70**, 230–236.
- Berryman A.A. (1999) Principles of population dynamics and their application. Stanley Thornes (Publishers) Ltd., Cheltenham, United Kingdom. 243 pp.
- Cameron A.C., Windmeijer F.A.G. (1996) R-squared measures for count data regression models with applications to health-care utilization. *Journal of Business & Economic Statistics*, **14**, 209–220.
- Doorenbos J., Kassam A.H. (1979) Yield response to water. FAO Irrigation and Drainage, Paper 33. Rome, Italy: Food and Agriculture Organization of the United Nations.
- Ferrero R., Lima M., Gonzalez-Andujar J. (2014) Spatio-temporal dynamics of maize yield water constraints under climate change in Spain. *PLoS One*, **9**, e98220.
- Ferrero R., Lima M., Davis A.S., Gonzalez-Andujar J.L. (2017) Weed diversity affects soybean and maize yield in a long term experiment in Michigan, USA. *Frontiers in Plant Science*, **8**, 1–10. <http://doi.org/10.3389/fpls.2017.00236>
- Grassini P.K., Eskridge M., Cassman K.G. (2013) Distinguishing between yield advances and yield plateaus in historical crop production trends. *Nature Communications*, **4**, 2918.
- IPCC (2014) Climate change 2014: impacts, adaptation, and vulnerability. Part B: regional aspects. In *Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. Eds V.R. Barros, C.B. Field, D.J. Dokken, M.D. Mastrandrea, K.J. Mach, T.E. Bilir, M. Chatterjee, K.L. Ebi, Y.O. Estrada, R.C. Genova, B. Girma, E.S. Kissel, A.N. Levy, S. MacCracken, P.R. Mastrandrea and L.L. White. Cambridge, UK and New York, NY, USA: Cambridge University Press. 688 pp.
- Lawlor D.W., Mitchell R.A.C. (2000) Crop ecosystem responses to climatic change: wheat. In *Climate Change and Global Crop Productivity*, pp. 57–80. Wallingford, UK: CAB International.
- Lawrimore J.H., Menne M.J., Gleason B.E., Williams C.N., Wuertz D.B., Vose R.S., Rennie J. (2011) An overview of the global historical climatology network monthly mean temperature data set, version 3. *Journal of Geophysical Research*, **116**, D19121.

- Lin M., Huybers P. (2012) Reckoning wheat yield trends. *Environmental Research Letters*, **7**, 024016.
- Lobell D.B., Burke M.B. (2010) On the use of statistical models to predict crop yield responses to climate change. *Agricultural and Forest Meteorology*, **150**, 1443–1452.
- Lobell D.B., Field C.B. (2007) Global scale climate–crop yield relationships and the impacts of recent warming. *Environmental Research Letters*, **2**, 014002.
- Lobell D., Schlenker W., Costa-Roberts J. (2011) Climate trends and global crop production since 1980. *Science*, **333**, 616–620.
- Lobell D.B., Sibley A., Ortiz-Monasterio J.I. (2012) Extreme heat effects on wheat senescence in India. *Nature Climate Change*, **2**, 186–189.
- Lobell D.B., Hammer G.L., McLean G., Messina C., Roberts M.J., Schlenker W. (2013) The critical role of extreme heat for maize production in the United States. *Nature Climate Change*, **3**, 497–501.
- Magrin G.O., Travasso M.I., Rodríguez G.R. (2005) Changes in climate and crop production during the 20th century in Argentina. *Climatic Change*, **72**, 229–249.
- Magrin G.O., Marengo J.A., Boulanger J.-P., Buckeridge M.S., Castellanos E., Poveda G., Scarano F.R., Vicuña S. (2014) Central and South America. In *Climate Change 2014: Impacts, Adaptation, and Vulnerability. Part B: Regional Aspects. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*, pp. 1499–1566. Eds V.R. Barros, C.B. Field, D.J. Dokken, M.D. Mastrandrea, K.J. Mach, T.E. Bilir, M. Chatterjee, K.L. Ebi, Y.O. Estrada, R.C. Genova, B. Girma, E.S. Kissel, A.N. Levy, S. MacCracken, P.R. Mastrandrea and L.L. White. Cambridge, UK and New York, NY, USA: Cambridge University Press.
- Maltais-Landry G., Lobell D.B. (2012) Evaluating the contribution of weather to maize and wheat yield trends in 12 US counties. *Agronomy Journal*, **104**, 301–311.
- McGrath J.M., Lobell D.B. (2013) Regional disparities in the CO₂ fertilization effect and implications for crop yields. *Environmental Research Letters*, **8**, 014054.
- Porter J.R., Xie L., Challinor A.J., Cochrane K., Howden S.M., Iqbal M.M., Lobell D.B., Travasso M.I. (2014) Food security and food production systems. In *Climate Change 2014: Impacts, Adaptation, and Vulnerability. Part A: Global and Sectoral Aspects. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*, pp. 485–533. Eds C.B. Field, V.R. Barros, D.J. Dokken, K.J. Mach, M.D. Mastrandrea, T.E. Bilir, M. Chatterjee, K.L. Ebi, Y.O. Estrada, R.C. Genova, B. Girma, E.S. Kissel, A.N. Levy, S. MacCracken, P.R. Mastrandrea and L.L. White. Cambridge, UK and New York, NY, USA: Cambridge University Press.
- Purves D., & Pacala S. (2008). Predictive models of forest dynamics. *Science*, **320**, 1452–1453.
- R Development Core Team (2011) *R: A Language and Environment for Statistical Computing*. Vienna, Austria: the R Foundation for Statistical Computing.
- Ray D.K., Ramankutty N., Mueller N.D., West P.C., Foley J.A. (2012) Recent patterns of crop yield growth and stagnation. *Nature Communications*, **3**, 1293.
- Ricker W.E. (1954) Stock and recruitment. *Journal of Fisheries Research Board of Canada*, **11**, 559–623.
- Royama T. (1977) Population persistence and density dependence. *Ecological Monographs*, **47**, 1–35.
- Royama T. (1992) *Analytical Population Dynamics*, pp. 371. London, UK, and New York, NY, USA: Springer/Chapman & Hall.
- Sadras V.O., Grassini P., Costa R., Cohan L., Hall A.J. (2014) How reliable are crop production data? Case studies in USA and Argentina. *Food Security*, **6**, 447–459.
- Sakamoto Y., Ishiguro M., Kitagawa G. (1986) *Akaike Information Criterion Statistics*. Dordrecht, The Netherlands: D. Reidel.
- Schlenker W., Roberts M.J. (2009) Nonlinear temperature effects indicate severe damages to U.S. crop yields under climate change. *Proceedings of the National Academy of Sciences of the United States of America*, **106**, 15594–15598.
- Shi W., Tao F., Zhang Z. (2013) A review on statistical models for identifying climate contributions to crop yields. *Journal of Geographical Sciences*, **23**, 567–576.
- Sowiński P., Rudzińska-Langwald A., Adamczyk J., Kubica L., Fronk J. (2005) Recovery of maize seedling growth, development and photosynthetic efficiency after initial growth at low temperature. *Journal of Plant Physiology*, **162**, 67–80.
- Verón S.R., de Abelleira D., Lobell D.B. (2015) Impacts of precipitation and temperature on crop yields in the Pampas. *Climatic Change*, **130**, 235–245.
- World Bank (2012) *World Development Indicators*. World Bank. URL <http://data.worldbank.org/data-catalog/world-development-indicators/wdi-2012>.
- Yoshida S. (1981) *Fundamentals of Rice Crop Science*. Manila, Philippines: International Rice Research Institute.
- Zia M.S., Salim M., Aslam M., Gill M.A., Rahmatullah (1994) Effect of low temperature of irrigation water on Rice growth and nutrient uptake. *Journal of Agronomy and Crop Science*, **173**, 22–31.

Supporting Information

Additional Supporting Information may be found in the online version of this article:

Appendix S1. Diagnostic tools and optimal models by region in South America for all cereals crops.

Appendix S2. How changes in the parameters of equation (1) translate the conditional production curve $R_t = f(Y_{t-d}, Z)$ moving it vertically or laterally, and changing its relative shape (nonlinear).

Capítulo 3

3. ¿Cómo afecta el cambio climático a la brecha en el rendimiento del maíz entre cultivos de secano y de regadío?

3.1 Introducción

Este capítulo aborda uno de los principales **desafíos** de la agricultura, **producir más con menos recursos** ([Godfray et al. 2010](#)). Mitigar los efectos del cambio climático y adaptarse a estos escenarios requiere hacer frente a los crecientes **conflictos entre la escasez de agua y la seguridad alimentaria** ([Mueller et al. 2012](#)).

En este artículo comparamos el rendimiento del maíz (*Zea mays*) en España en sistemas agrícolas **con y sin riego**. Evaluamos **cómo y dónde podemos utilizar el riego de manera efectiva** para aumentar la producción del cultivo y mitigar los efectos del cambio climático sin comprometer los recursos hídricos.

El maíz es uno de los tres cultivos más importantes del mundo (junto con el trigo y el arroz) con una producción total de 820 millones de t/año en 2008. Según las últimas estadísticas, España ocupa el puesto 27 en el ranking de países productores a nivel mundial pero es el noveno en el

ámbito de Europa ([MAGRAMA 2008](#)). Se trata de una planta con unas **necesidades hídricas importantes** ([Doorenbos & Kassam 1979](#)) que se cultiva durante un período (verano) donde las precipitaciones escasean y en el que el agua contenida en los acuíferos está menos disponible en España.

España presenta una gran dependencia del agua para riego, el 68% del agua que se consume se dedica a regar y ocupa el primer puesto en la Unión Europea con 3,63 millones de hectáreas regadas ([MAGRAMA 2018](#)). Y además, la zona mediterránea **es un "punto crítico"**, una de las zonas que sufrirá con más intensidad las consecuencias del **cambio climático** ([Porter et al. 2014](#)). El sur de Europa ya está registrando un mayor aumento en las temperaturas máximas y menores niveles de precipitaciones, así como una disminución del caudal de los ríos y un aumento de la aparición de sequías; lo que se espera se traduzca en daños en los cultivos ([IPCC 2014](#)).

La gestión eficaz del riego es crucial ante el cambio climático ([Siebert & Döll 2010](#)). En un escenario marcado para el aumento de la demanda de agua, el riego se vuelve uno de los principales instrumentos para la adaptación de la agricultura al cambio climático. Sin embargo, la disponibilidad del agua para riego es cada vez más escasa en la región.

El capítulo contiene el artículo “*Spatio-temporal dynamics of maize yield water constraints under climate change in Spain*” publicado en la revista PLOS ONE (Q1) (ver pág. 4). El material complementario de este artículo se encuentra disponible en el apéndice.

3.2 Spatio-Temporal Dynamics of Maize Yield Water Constraints under Climate Change in Spain

OPEN ACCESS Freely available online

PLOS ONE



Spatio-Temporal Dynamics of Maize Yield Water Constraints under Climate Change in Spain

Rosana Ferrero^{1,4*}, Mauricio Lima^{2,3,4}, Jose Luis Gonzalez-Andujar^{1,3}

1 Departamento Protección de Cultivos, Instituto de Agricultura Sostenible, Consejo Superior de Investigaciones Científicas (CSIC), Córdoba, Spain, **2** Departamento de Ecología, Pontificia Universidad Católica de Chile, Santiago, Chile, **3** Laboratorio Internacional de Cambio Global, LINCG (CSIC-PUC), Santiago, Chile, **4** Center of Applied Ecology and Sustainability (CAPEs), Santiago, Chile

Abstract

Many studies have analyzed the impact of climate change on crop productivity, but comparing the performance of water management systems has rarely been explored. Because water supply and crop demand in agro-systems may be affected by global climate change in shaping the spatial patterns of agricultural production, we should evaluate how and where irrigation practices are effective in mitigating climate change effects. Here we have constructed simple, general models, based on biological mechanisms and a theoretical framework, which could be useful in explaining and predicting crop productivity dynamics. We have studied maize in irrigated and rain-fed systems at a provincial scale, from 1996 to 2009 in Spain, one of the most prominent “hot-spots” in future climate change projections. Our new approach allowed us to: (1) evaluate new structural properties such as the stability of crop yield dynamics, (2) detect nonlinear responses to climate change (thresholds and discontinuities), challenging the usual linear way of thinking, and (3) examine spatial patterns of yield losses due to water constraints and identify clusters of provinces that have been negatively affected by warming. We have reduced the uncertainty associated with climate change impacts on maize productivity by improving the understanding of the relative contributions of individual factors and providing a better spatial comprehension of the key processes. We have identified water stress and water management systems as being key causes of the yield gap, and detected vulnerable regions where efforts in research and policy should be prioritized in order to increase maize productivity.

Citation: Ferrero R, Lima M, Gonzalez-Andujar JL (2014) Spatio-Temporal Dynamics of Maize Yield Water Constraints under Climate Change in Spain. PLoS ONE 9(5): e98220. doi:10.1371/journal.pone.0098220

Editor: Pilar Hernandez, Institute for Sustainable Agriculture (IAS-CSIC), Spain

Received: November 13, 2013; **Accepted:** April 29, 2014; **Published:** May 30, 2014

Copyright: © 2014 Ferrero et al. This is an open-access article distributed under the terms of the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original author and source are credited.

Funding: R. Ferrero gratefully acknowledges receipt of a grant from the Fundación Carolina. J. L. Gonzalez-Andujar and R. Ferrero were supported by FEDER (Fondo Europeo de Desarrollo Regional) and the Spanish Ministry of Economy and Competitiveness funds (AGL2012-33736). R. Ferrero and M. Lima acknowledge financial support from Fondo Basal-CONICYT grant FB-0002. We are grateful to LINCGlobal (Laboratorio Internacional en Cambio Global) for their support. The funders had no role in study design, data collection and analysis, decision to publish, or preparation of the manuscript.

Competing Interests: The authors have declared that no competing interests exist.

* E-mail: rferrero@ias.csic.es

Introduction

Spatio-temporal patterns of agricultural production are clearly influenced both by climate change and agricultural management practices. Recently, many studies have analyzed the impact of climate change on crop productivity [1], but comparing the performance of different crop management systems has rarely been explored (exc. [2]). To be specific, we need to evaluate how and where irrigation practices (e.g. rain-fed versus irrigated) are effective in mitigating the effects of climate change, because water constraints and crop demand in agro-systems could be increased due to climate change [3–7]. Identifying whether there are any differences in the principal bio-physical factors and mechanisms that explain both systems will enable us to improve crop productivity without expanding the cropland area and to diminish the adverse impacts of agriculture for social and ecological systems [8].

We do not know much about crop response to climate change yet, and still less about the differential response between irrigated and rain-fed systems [4]. Increases in agriculture production could potentially come from increases in irrigated crops, because higher yields could be attained with reduced production variability [9].

However, this also depends on soil and management factors that result in spatial patterns of yields [10]. Secondly, irrigation can influence local climate by inducing cooling, but this may depend on the extent of the irrigated area, the level of soil moisture alteration and cloud response to irrigation [11]. Third, average yields in rain-fed systems are commonly 50% or less of yield potential (high yield gap), suggesting ample room for improvement [12] but, again a great spatial variability has been found [13]. Yield gaps could be bigger in cropping systems that experience wider ranges of variation under climate conditions [10]. Fourth, plant population (or density) is known to affect the yield potential at a given location [12] and grain yield stability [14]. However, to our knowledge, there are no previous studies explicitly comparing endogenous processes under different water management systems. Finally, simulation at a broad scale level cannot fully explain the above process, and process-based crop models do not always relate to observed yields [15]. Finer spatial scales and historical data of irrigated versus rain-fed systems could help to compare modelled or simulated yield potentials [12].

Analyzing the sensitivity of irrigated and non-irrigated (rain-fed) crops to past climate changes is crucial to an understanding of the vulnerability of agriculture to climate change in the future,

particularly in regions that already suffer from this under present conditions. This paper explores biophysical factors and water management practice constraints to maize (*Zea mays* L.) in Spain. Spatial shifts northwards have been projected for maize, due to the extremely hot, dry summers in south-central Europe [16,17], particularly in Spain [18]. The expected effects of climate change on Spain's agriculture would not be uniform. Mediterranean (arid and semiarid) regions may be particularly sensitive, where a decrease in the general availability of hydric resources and an increase in evaporative demand, especially during summer, will affect irrigation requirements [19]. Namely, it is one of the most prominent "hot-spots" in future climate change projections [20], where a mean reduction of 17% in water resources [21,22] has been predicted. For this drought-prone zone, all climate change scenarios imply the need to significantly increase the contribution of irrigation water. Therefore, identifying and quantifying the links between water management practices and food production is crucial in addressing the intensified conflicts between water scarcity and food safety.

The objective of this paper is to determine how climate variability affects maize production in Spain under irrigated and rain-fed conditions. First, we have analyzed the regulatory structure of maize production dynamics under both water management systems. Second, we have evaluated the mechanisms (in ecological parameters) underlying climate perturbations on maize yields. Third, we have assessed whether the importance of maize production structures (i.e. intrinsic regulation) and climate change perturbations (i.e. exogenous factors) could change according to the type of management (i.e. rain-fed and irrigated) and the geographical location. Fourth, we have estimated the potential yield of each region and water management using the previous models and analyzing the spatial variability of yield losses due to water stress [23]. We have combined information on spatial autocorrelation water stress patterns for maize yields to identify the importance of climate constraints at a regional scale.

Methods and Materials

Database

Provincial maize yield levels (*Zea mays*; production per hectare, *kg/ha*) for 1996–2009 were obtained from statistical yearbooks [24]. We studied selected provinces that had both rain-fed and irrigated systems (Fig. 1), and displayed trends in yield fluctuation in Fig. S1. We used Global Historical Climatology Network (GHCND) data on monthly temperature and rainfall (mean, minimum, maximum and extreme; [25]). Various summary statistics of the growing season (July to October) weather were then computed: *EMNT* extreme minimum temperature (°C), *EMXT* extreme maximum temperature (°C), *MMNT* mean minimum temperature (°C), *MMXT* mean maximum temperature (°C), *MNTM* mean temperature (°C), *EMXP* extreme maximum daily precipitation total (l/m²) and *TPCP* total precipitation (l/m²). We also examined carbon dioxide emission (*CO₂*), an important atmospheric gas that contributes to global warming. The annual country-level emissions of *CO₂* (*kt*) were taken from the World Bank's World Development Indicators (WDI; [26]).

Diagnosis and statistical models of yields dynamics

We have analyzed and predicted maize yield responses to the impact of climate change in Spain through the use of models based on the population dynamics theory. Of course this is not a true population in the reproductive sense, but crop systems obey the same rules as all other dynamic systems, both natural and engineered.

First, where necessary, we used sequencing (i.e., splitting the series into two stationary segments) and detrending (i.e., rotating the series around the linear or quadratic trend) to generate a stationary time series. Second, we estimated the logarithmic rate of change of the yield as $R_t = Y_t - Y_{t-1}$ (the same response variable as [1,27]), where Y_t represents the provincial yield in a year t (the logarithm of the detrended yield) and Y_{t-1} is the same series with one year of delay (lag 1).

We were able to detect and analyze non-trivial feedback processes by examining their relationship $R_t = f(Y_{t-d})$, where the function f described how the crop yield change rate varied with yield level, and this has been called the *R*-function. We used the partial rate correlation function (or *PRCF*) to estimate the order of the dynamical process and determine how many time lags (d) should be included in the model for representing the feedback structure. This function detects the feedback order removing the confounding effect by calculating the partial correlation between R_t and Y_{t-d} with the effects of lower lags removed [28].

We then used the generalized version of the exponential form of the discrete time logistic model [29,30] in terms of the *R*-function to represent pure endogenous models in the function f :

$$R_t = r_{\max} - \exp(a Y_{t-d} + c) \quad (1)$$

where Y_{t-d} represents the yield data at time $t-d$ (where d was obtained from *PRCF* function), r_{\max} is a positive constant representing the maximum finite rate of change (and is estimated as the maximum rate of change from the observed data), c is a measure of the ratio between demand and offer of limiting resources and a is the nonlinearity of the curve. The nonlinearity of this model includes a biological realistic property: its net reproductive rate is bounded [29], that is, the performance of any crop must have an upper bound simply because no crop can produce an infinite number of grains that subsequently contribute to the crop yield.

Finally, we used the Royama classification of exogenous effects as a framework to deduce causal mechanisms of the climate change impact on these crop yields in a spatial-temporal study [29]. To include exogenous perturbations, we modelled r_{\max} and c of (1) as linear functions of climate conditions, each of which has an explicit biological interpretation. In this way, we set up mechanistic hypotheses about the exogenous effects of climate on these yields data [29].

If an exogenous factor (i.e. climate or gas emissions) changes r_{\max} and has an additive or independent perturbation effect on crop yield levels, it shifts the *R*-function curve along the y -axis ("vertical" perturbations):

$$\begin{aligned} r_{\max}^* &= r_{\max} + b Z_{t-d} \\ R_t &= r_{\max} - \exp(a Y_{t-d} + c) + b Z_{t-d} \end{aligned} \quad (2)$$

where Z_{t-d} is the exogenous factor (for lags or d 0 and 1; in logarithm scale). This model produces alterations to both r_{\max} and the carrying capacity (equilibrium point of the population, $R_t = 0$), changing the level of equilibrium and its stability.

If an exogenous factor (i.e. climate or gas emissions) changes c and has a non-additive perturbation effect on crop yield levels, and influences the equilibrium point of the population shifting the *R*-function curve along the x -axis ("lateral" perturbations):

$$\begin{aligned} c^* &= c + b Z_{t-d} \\ R_t &= r_{\max} - \exp(a Y_{t-d} + c + b Z_{t-d}) \end{aligned} \quad (3)$$

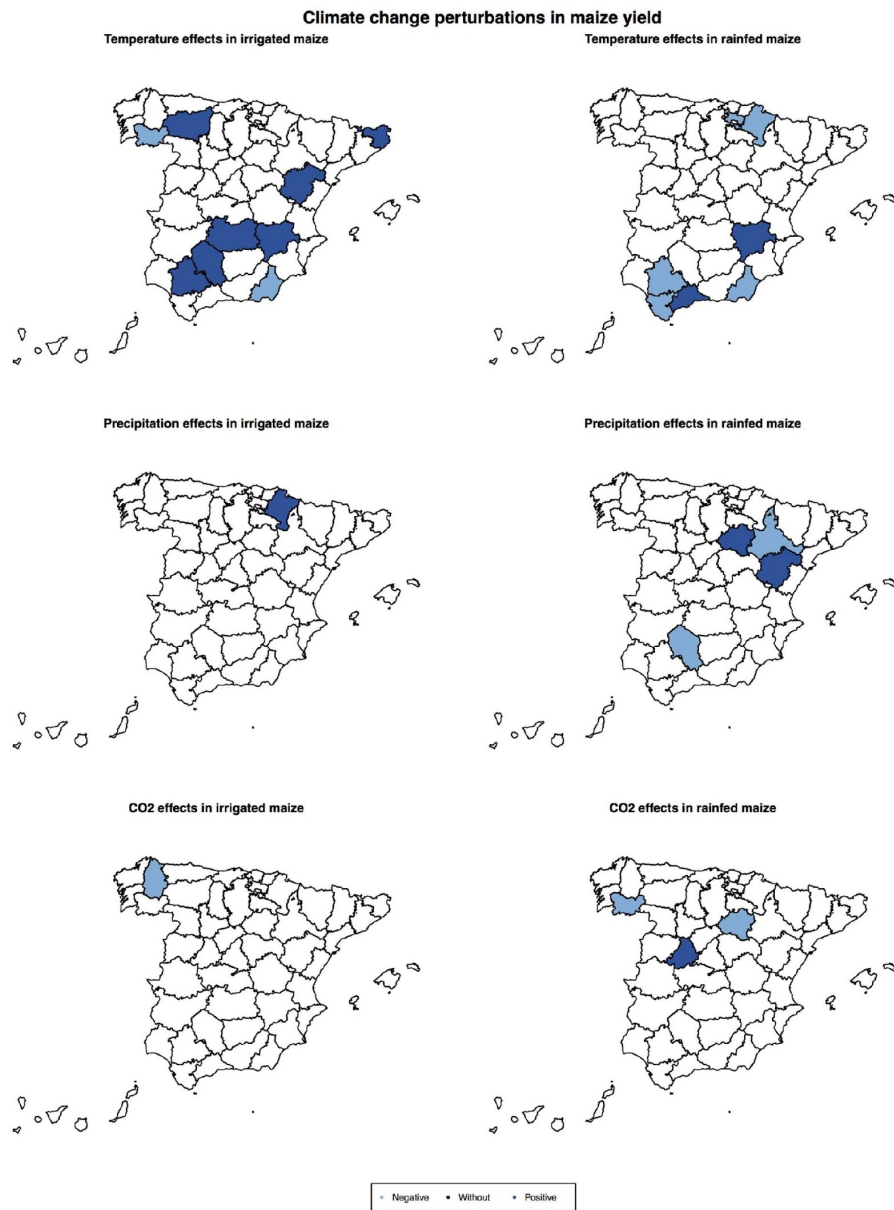


Figure 2. Effects of temperature, precipitation and CO2 emission, on maize productivity for rain-fed and irrigated crops. Provinces for both water management systems were selected for the analysis. All models are from Table S1. doi:10.1371/journal.pone.0098220.g002

ence on Moran's I using 999 simulations (Monte Carlo permutation test). Also, local indicators of spatial association (or LISA) were calculated to detect "hot spots" where there was a strong autocorrelation, and "cold spots", where there were none. The results were plotted on a Moran scatterplot: the target variable on the x -axis, and the (spatially-weighted) sum of neighbouring values on the y -axis; these are called spatially lagged values. We identified the high-influence areas.

We analyzed the environmental spatially distributed causes of averaged YGR_w through a Simultaneous Autoregressive Model (SAR; [36]) that considers spatial autocorrelation of residuals:

$$YGR_w = Z^T \beta + e \quad (5)$$

where, for each province, YGR_w is the percentage of yield losses due to suboptimal water availability, Z is a matrix of averaged climate variables (see Database section; except country-level CO_2 emissions), $e = B(Y - Z^T \beta) + \epsilon$ is the error term, and ϵ represents residual errors (assumed to be independently distributed according to a Normal distribution with zero mean and diagonal covariance matrix σ_e^2). The error terms are modelled so that they depend on each of the other areas to account for their spatial dependence (B is a matrix that contains the dependence parameters; $B = \lambda W$, where λ is a spatial autocorrelation parameter and W is a matrix that represents the spatial dependence explained above). Global Moran's I was computed for the residuals to test if the SAR model accounts for all the spatial autocorrelations in YGR_w . For the spatial analysis we used *spdep* library in the software R [37].

Results

Regulatory structure and exogenous perturbation models

After sequencing and detrending, all the sites exhibited first-order negative feedback ($PRCF(1)$) as being the most important component of yield growth rate (Figure S2; except for irrigated maize in Vizcaya and rain-fed systems in Tarragona). Major sites showed the highly significant ($p < 0.05$) effect of endogenous processes as determinants of the structure of crop productivity regulation (Table S1).

We evaluated gas emission (CO_2) and climate factors (temperature and precipitation; see Database section), as exogenous perturbations of the production curve (R -function). Table S1 shows several models that were selected as climate change impacts on maize production for each Spanish region and management system. The stochastic versions of the step-ahead predictions of the models are shown in Fig. S3. As expected, the effects of climate on maize production were not uniform, and depended on the irrigation management system (Figure 2). Maize yields were significantly related to minimum temperatures (possibly night ones) in 11 sites and by maximum temperature in another 5 sites. Generally, there were positive effects of temperature for irrigated systems, except for Almería (for minimum temperature $-EMNT$) and Ourense (mean temperature $-MNTM$). However, for rain-fed systems, we detected negative effects of warming on major sites, with the exception of Málaga and Albacete (both for $EMNT$). As expected, precipitation was not important for irrigated systems (except for maximum precipitation $-EMXP$ in Navarra), but it was an important factor in some rain-fed managements. There

were positive effects of precipitation on Teruel and Soria (for a total $-TPCP$ and maximum rainfall), and negative ones in Córdoba ($TPCP$ and $EMXP$) and Zaragoza ($TPCP$) on rain-fed crops. Finally, CO_2 emissions negatively affected maize in Lugo (irrigated), Ourense and Soria (both rain-fed), and positively only in Ávila (rain-fed).

Temperature acted mainly as having non-additive (lateral) effects on maize yield dynamics, whereas CO_2 emission acted as additive (vertical) effects (Table S1; Figure 3 and S4). Finally, rainfall exerted non-additive effects when it had a negative impact on maize, but when it obtained positive responses the effects were of both types (additive or non-additive; Table S1; Figure S4). For example, Figure 3 shows positive and non-additive (lateral) effects of temperature on rain-fed maize in Albacete and irrigated maize in Sevilla. That is, the increase in temperature had a positive effect on both maize systems, and more so at high yield levels. Figure 3 also indicates a negative and additive (vertical) effect of CO_2 emission on Ourense (same strength for all yield levels), and a positive and non-additive (lateral) rainfall effect on rain-fed maize in Soria (more important for high yield levels).

Relative yield losses due to suboptimal water availability (YGR_w)

We first visualized the spatial relation of YGR_w (Figure 4), where several high YGR_w values were shown in central and southern provinces of Spain. The global Moran's I value ($I = 0.39$) was of an opposite sign and much larger in absolute value than the expectation ($E[I] = -0.034$); this was quite unlikely to be equal to the expectation of no spatial association. The probability of incorrectly rejecting the null hypothesis of no association (type I error) was 0.0021. The Monte Carlo approach also rejects the null hypothesis (the true value for Moran's I is zero; $I_{nc} = 0.406$, $p = 0.005$; Figure S5). The Moran scatterplot (Figure 5; the vector of values and the neighbour list with weights) showed points with a great influence, which are identified by a special symbol and their name. The highest-leverage area is marked on Almería; it has the highest YGR_w (84.56) and a zero weighted spatially-lagged proportion, because it did not have any adjacent areas in the study. Soria and Palencia had low YGR_w , and a low spatially-lagged proportion; these are the low- YGR_w neighbourhoods adjacent to low- YGR_w neighbourhoods. They have a great influence on the slope (global Moran's I). From Figure 5 it is clear that most of the global Moran's I significance comes from the local Moran's I from high YGR_w in Almería, and low YGR_w associated with low YGR_w in the Soria and Palencia area in the north.

There was clear evidence of local clustering, 6 areas (Ciudad Real, Cuenca, Albacete, Valencia, A Coruña and Pontevedra) showed sufficiently high local Moran's I to reject the null hypothesis with less than a 5% chance of Type I error. These areas were not highlighted in the Moran scatterplot, as they did not greatly influence the global Moran's I but were locally-clustered.

There was a significant spatial correlation in the residuals, because the estimated value of lambda was 0.141 and the p -value of the likelihood ratio test 0.0354. Only averaged temperature ($MNTM$) was significant for the SAR model, suggesting that provinces with higher temperature have larger YGR_w percentages. The model found was: $YGR_w = -64.42 + 5.69 * MNTM$, the SAR model, which accounted for the whole spatial autocorrelation

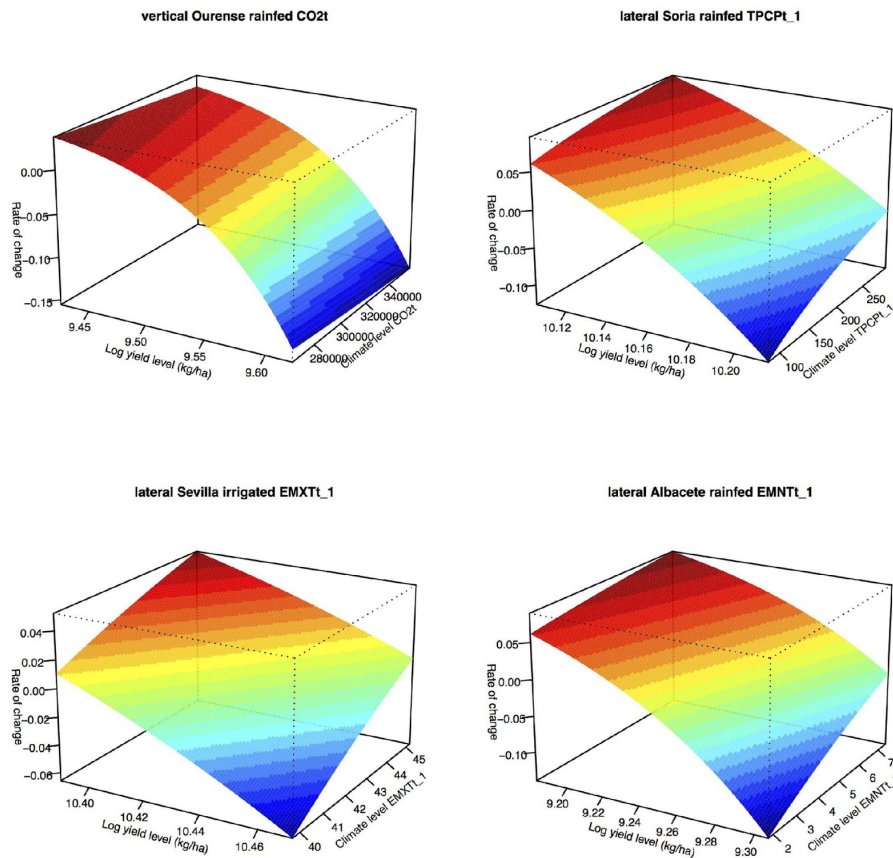


Figure 3. Yield rate of change against the log observed yield level (with one year of delay) and the exogenous factor that perturbs the productivity function (R -function). Exogenous factors include carbon emissions (CO_2), precipitation ($TPCP_{t-1}$), and maximum and minimum temperature ($EMXT_{t-1}$ and $EMNT_{t-1}$). Additive (vertical) and non-additive (lateral) perturbation effects were detected. Colours indicate the R -function value. See Table S1 for description of models and Figure S4 for their graphs. doi:10.1371/journal.pone.0098220.g003

in YGR_w (global Moran's test for residuals was $I = -0.00811$, $p = 0.422$). Thus, the autocorrelation in the linear model residuals was explained.

Discussion

In the present study, the impact of climate variability on maize yields in Spanish rain-fed and irrigated systems was investigated for the period 1996–2009. We explored the endogenous structure (regulation) and the exogenous perturbations effects on maize production at a regional scale.

Regulatory structure: endogenous feedback

We found that maize productivity had a persistently negative effect on crop yields for a one year time delay (first order negative feedback, $PRCF(1)$). Maize productivity was characterized by negative first-order feedback structure in major sites and in both irrigation systems. Namely, there were biomass or density-induced feedback loops in the growth, survival rates, seed germination or grain production rates of individual plants, tending to stabilize their dynamics [38]. In Spain, the seeds produced are used for the next year and, therefore, a year's crop performance could change seed viability and vigour, which also affects the performance of the following crops (changing the demand for resources). Also, a crop

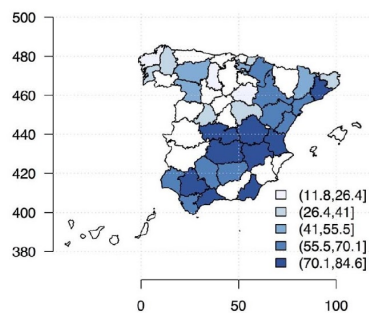


Figure 4. Relative yield losses due to suboptimal water availability (YGRM, %). The percentage of yield losses due to suboptimal water availability indicates how close rain-fed yield potential are to the irrigated value for a given site.
doi:10.1371/journal.pone.0098220.g004

system could alter habitat conditions; in fact, the frequent practice of crop rotation is a testimony to the importance of negative feedbacks in agricultural systems (i.e. it modifies resource supplies). This produces high-frequency dynamics due to year-to-year endogenous variability in maize yields. Our logistic models appear to capture the essential features of the fluctuations observed, and suggest a mechanistic explanation for the latter. This implies that, to understand the response of maize productivity to climate, we must also know the endogenous feedback structure of the system.

Our models are important to conceptualizing the problem of regulated versus unregulated systems. If a system were to be controlled entirely by an exogenous process (unregulated systems), then the series would perform a random walk and we saw no sign of the generated series becoming stabilized, but it drifted increasingly away from the origin with the passing of time [29]. However, persistence implies regulation (but not necessarily vice versa) and, therefore, the rate of change in a persistent crop productivity system is not statistically independent of the yield level and should be bounded (i.e. regulated systems).

Climate change effects: exogenous perturbations

In line with previous studies, temperature during the growing season was the most important weather variable influencing maize yields [39]. However, we deciphered the effects of climate on maize productivity providing new interpretations. First, diagnostic analysis suggested that temperature acts mainly as a non-additive (lateral) perturbation in maize productivity. Therefore, the relationship between temperature and maize yields was nonlinear and could not be captured adequately by a linear or quadratic functional relation as in previous studies [40]. Our analysis suggests a biological reason for the nonlinear interaction between climate and maize yield level. Temperature had no direct impacts on yield rate of change (affecting r_{max} ; additive or vertical effects), but influenced the availability or requirements of some limiting factor or resource (changing c ; non-additive or lateral effects). There is probably a relationship between extreme heat and plant water stress, increasing water demand and/or soil water content in rain-fed systems, in agreement with the recent results of Lobell *et al.* [41]. This is because, the effects of high temperature are experienced only when the maize yield level is close to equilibrium [29]. This kind of perturbation exerts strong effects on the average

level of yield but few on the intrinsic periodicity induced by endogenous feedback.

Secondly, rain-fed maize yields are negatively affected by temperature increases, but irrigated systems may gain from warming in some regions. As expected, rain-fed crop damage may result from greater water and heat stress during hot growing seasons. However, unexpected positive effects of temperature in irrigated systems are possibly a consequence of heat tolerance, which is consistent with other studies on local adaptation to hot temperatures being able to minimize stress effects [40] or the cooling effect of irrigation [42]. Therefore, we detected some adaptation to heat stress that could mitigate the projected heat-related losses, at least in a few regions with irrigated systems.

Thirdly, climate variability and extreme events are more important than averages. Thus, we detected that minimum temperature was the dominant factor in maize production, in agreement with other recent studies for maize [43–45] and rice [46]. Currently, a new paradigm has been originated: crop yields have declined with a higher minimum or night temperature [46,47] or when there was a marked asymmetry between maxima and minima [48]. One possible explanation includes the facts that the grain-growth rate has increased and that the duration of grain-filling has been shortened as the temperature increased, producing lower crop production (yield levels) [49]. Mohammed & Tarpley [47] proposes a list of the effects of high night temperatures on crop production. Also, our findings are in line with the results of recent research which argue that global minimum temperatures are increasing faster than maximum temperatures, and the need to explore the ecological consequences of this phenomenon [41,50,51]. Therefore, we wish to highlight the importance of considering extreme climate variables in crop production studies, and limiting the use of averages or accumulative climate data which ignore inter-annual variability of climate and extreme events. Our results differ from those of most studies which do not take into account food production structure regulation, and those which use degree-days [40] concepts which assume a cumulative or additive effect of temperature on crop yield and do not adequately account for the effects of extreme temperatures (high or low) either.

In the study period, precipitation was not a major abiotic factor limiting maize yield of cultivated rain-fed crops in Spain. We only detected positive effects of precipitation for irrigated maize in Navarra, Teruel and Soria. Also, growing season rainfall negatively affected rain-fed maize yield in Córdoba and Zaragoza, possibly due to flood and waterlogging problems causing production losses. Again, we agree with Lobell *et al.* [41], who argue that the apparent paradox of the scant effect of precipitation on rain-fed maize yield whereas, on the contrary, there is a water stress effect of temperature, can be solved with the following reflection “large precipitation changes are required to rival the effect of temperature on water stress, because high temperature affects both water demand and supply”.

As in the study of Long *et al.* 2006 [52], ours study indicates that there was a smaller CO_2 effect on maize yield than previously presumed. Impacts of higher CO_2 on maize yield were reduced probably because it is a C4 plant, and also because of the national scale of the variable in our study.

Spatial variability of yield losses due to water stress

We found that the global spatial pattern of yield losses due to water stress is not a random one (Figure 4); there was a high influence in Palencia, Soria (lowest) and Almería (highest). We detected clusters of “cold spots” in northern Spain (A Coruña and Pontevedra) and “hot spots” in central provinces (Ciudad Real,

Cuenca, Albacete, Valencia; Figure 5). Neither cluster greatly influenced the global Moran's I but they were locally-clustered. Moreover, we modelled spatial YGR_w values with climate variables and found that the mean temperature was the highest constraint of maize productivity due to water stress. In conclusion, policy action to decrease the relative yield gap due to water stress on maize productivity has the potential to geographically target high YGR_w areas. Future work will help determine other non-climatic causal relationships between YGR_w and an array of factors that could influence water management practices in maize (e.g. access to water, management technology, soil conditions, etc.).

A recent comparison of simulated and observed yield patterns highlights the value of data in the spatial distribution of yields for understanding the causes of landscape yield variability [10].

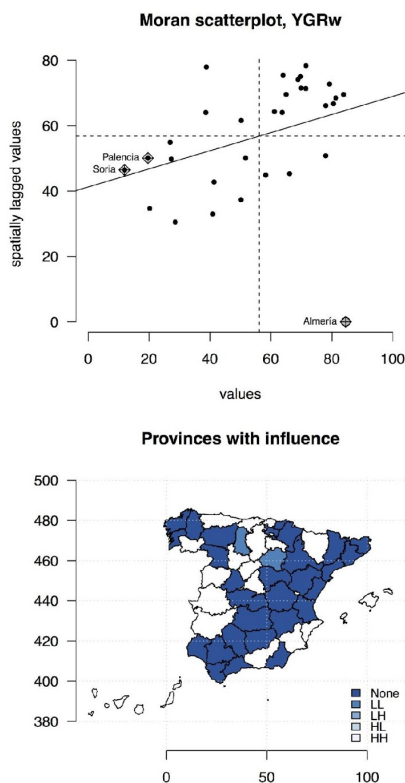


Figure 5. Spatial autocorrelation analysis of the relative yield losses due to suboptimal water availability (YGR_w). Top: Moran scatterplot; bottom: high-influence areas neighbours: no influence (None), high proportion with low proportion neighbours (HL), the reverse (LH), and both high (HH). We define the break between "low" and "high" as the third quartile.
doi:10.1371/journal.pone.0098220.g005

However, to our knowledge, this is the first study explicitly evaluating the spatial pattern of real relative yield gaps due to a water management system and its sensitivity to underlying climate factors. The results demonstrate that spatial patterns of yield loss due to water stress possess substantial information on the relative importance of water management factors for maize productivity.

The need for an analysis to identify and implement adaptation options in agriculture emphasizes the importance of regional scales (federal, provincial, and territorial governments). Global and non-spatial studies can provide only a very partial and potentially misleading insight into the true impact of climate change, where aggregation can indeed conceal vulnerability and climate change costs [53]. However, individual regions (provinces) allow a better analysis of uncertainty and risks, thus providing practical recommendations to farmers.

Conclusions

We identified the same regulation structure for both management systems, i.e. a negative first-order feedback process that tends to stabilize the crop's dynamics. We analyzed the underlying mechanisms of the interaction between climate variation and regulatory structure on maize production. Different climate variables appear to operate differently on maize productivity. We found that the effect of temperature (mainly extreme values) cannot be evaluated independently of crop productivity as in previous studies, because its consequences are experienced only when maize yield level is close to equilibrium (lateral perturbation). We suggest that high maize yield crops are especially vulnerable to weather-related yield variations. These data support the belief that lower yields are more suitable for low-input conditions, because climate might be more severe in crops that interact strongly with productivity [14].

Our results also indicate that it may be important to consider explicitly the irrigation system and spatial variability. Rain-fed agriculture may be at risk as heat waves will be more intense, more frequent and longer (particularly in Seville, Cádiz, Almería, Navarra and Ávila; see Fig. 2). Irrigation seems to allow some tolerance to warming but future levels of water availability would be compromised if water restrictions and irrigation costs increased, as climate change projections indicate. We propose a new framework to estimate yield potential as the equilibrium yield or yield carrying capacity. Climate change is not uniform over Spain and the effectiveness of irrigated and rain-fed management varies with the location, producing different regional vulnerabilities and potential yields. Accordingly, the general strategies for adapting maize productivity to climate change will vary between different zones in Spain.

Supporting Information

Figure S1 Time series of maize yield level for rain-fed (red) and irrigated (blue) systems. Each provinces of Spain were analyzed for 1996–2009.
(TIFF)

Figure S2 Partial rate correlation function (PRCF).
(TIFF)

Figure S3 Comparison of observed crop yield levels (points, obs) for the period 1997–2009 with stochastic predictions from models fitted to the data until the year 1996 (broken line, sim) and 95% confidence intervals for forecasts (shaded area, 95PPU). P-factor is the percent of observations that are within the given uncertainty bounds and R-factor represents the average width of the given uncertainty

bounds divided by the standard deviation of the observations. See Table S1 for description of models and variables. (TIFF)

Figure S4 R-functions: yield rate of change against the log observed yield level (with one year of delay). Climate factors had vertical (additive) and lateral (non-additive) perturbations on the *R*-function. Colors indicate the value of the *R*-function. See Table S1 for description of models and variables. (TIFF)

Figure S5 A non-parametric approach to inference on Moran's *I* using 999 simulations (Monte Carlo permutation test). (TIFF)

Table S1 Summary statistics of nonlinear logistic models, 1996–2009. We evaluated pure Endogenous models (E), and additive (or Lateral, L) and non-additive (or Vertical, V) models that also represent the effect of exogenous perturbations. Different crop management systems were analyzed (*IR* = irrigated and *RF* = rain-fed). %*Total* percentage of total crop production in Spain, *K* carrying capacity or potential yield, *mmax* maximum finite reproductive rate, *a* non-linearity coefficient, *c* the ratio between demand and offer of limiting resources, *b* coefficients for different

exogenous effects, *R*² pseudo-coefficient of determination, *logLIK* log-likelihood, *RMSE* root-mean-square error and *AICc* corrected Akaike information criterion. NOTE: **p* < 0.05, ***p* < 0.01, Number of not available data (NA) were indicated by I. *CO2* carbon dioxide emission (*kt*, country-level emissions), and summary statistics of the growing season weather: *EMNT* extreme minimum temperature (°C), *EMXT* extreme maximum temperature (°C), *MMNT* mean minimum temperature (°C), *MMXT* mean maximum temperature (°C), *MNTM* mean temperature (°C), *EMXP* extreme maximum daily precipitation total (l/m2), *TPCP* total precipitation (l/m2). (DOC)

Acknowledgments

We thank the editor and two anonymous reviewers for their constructive comments, which helped us to improve the manuscript.

Author Contributions

Conceived and designed the experiments: RF ML JLG-A. Performed the experiments: RF. Analyzed the data: RF. Contributed reagents/materials/analysis tools: RF. Wrote the paper: RF ML JLG-A.

References

- Lobell DB, Schlenker W, Costa-Roberts J (2011) Climate trends and global crop production since 1980. *Science* 333: 616–620.
- Licker R, Johnston M, Foley JA, Barford C, Kucharik CJ, et al. (2010) Mind the crop: how do climate and agricultural management explain the “yield gap” of croplands around the world? *Glob Ecol Biogeogr* 19: 769–782.
- Döll P (2002) Impact of climate change and variability on irrigation requirements: a global perspective. *Clim Change* 54: 269–293.
- Turrill H, Burke J, Faurès JM, Faurès JM (2011) Climate change, water and food security. Rome Food Agric Organ United Nations: 204.
- Easterling WE, Aggarwal PK, Batima P, Brander KM, Erda L, et al. (2007) Food, fiber and forest products. In: Parry ML, Canziani OF, Palutikof JP, Linden PJ van der, Hanson CE, editors. *Climate Change 2007: Impacts, Adaptation and Vulnerability*. Contribution of Working Group II to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press, Cambridge, UK. pp. 273–313.
- Smith P, Martino D, Cai Z, Gwary D, Janzen H, et al. (2007) Agriculture. In: Metz B, Davidson OR, Bosch PR, Dave R, Meyer LA, editors. *Climate Change 2007: Mitigation*. Contribution of Working Group III to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA. pp. 497–540.
- Medici LO, Reinert F, Carvalho DF, Kozak M, Azevedo RA (2014) What about keeping plants well watered? *Environ Exp Bot* 99: 38–42.
- Zou X, Li Y, Gao Q, Wan Y (2011) How water saving irrigation contributes to climate change resilience—a case study of practices in China. *Mitig Adapt Strateg Glob Chang* 17: 111–132.
- Mueller ND, Gerber JS, Johnston M, Ray DK, Ramankutty N, et al. (2012) Closing yield gaps through nutrient and water management. *Nature* 490: 254–257.
- Lobell DB, Ortiz-Monasterio JL (2006) Regional importance of crop yield constraints: Linking simulation models and geostatistics to interpret spatial patterns. *Ecol Modell* 196: 173–182.
- Lobell D, Bala G, Mirin A, Phillips T, Maxwell R, et al. (2009) Regional Differences in the Influence of Irrigation on Climate. *J Clim* 22: 2248–2255.
- Lobell DB, Cassman KG, Field CB (2009) Crop Yield Gaps: Their Importance, Magnitudes, and Causes. *Annu Rev Environ Resour* 34: 179–204.
- Meng Q, Hou P, Wu L, Chen X, Cui Z, et al. (2013) Understanding production potentials and yield gaps in intensive maize production in China. *F Crop Res* 143: 91–97.
- Tokatlidis IS (2013) Adapting maize crop to climate change. *Agron Sustain Dev* 33: 63–79.
- Reidman P, Ewert F, Boogaard H, van Diepen K (2009) Regional crop modelling in Europe: The impact of climatic conditions and farm characteristics on maize yields. *Agric Syst* 100: 51–60.
- Olesen JE, Carter TR, Diaz-Ambrona CH, Fronzek S, Heidmann T, et al. (2007) Uncertainties in projected impacts of climate change on European agriculture and terrestrial ecosystems based on scenarios from regional climate models. *Clim Change* 81: 123–143.
- Wolf J, Diepen CA (1995) Effects of climate change on grain maize yield potential in the European community. *Clim Change* 29: 293–331.
- Iglesias A, Minguéz MI (1995) Prospects for maize production in Spain under climate change. In: Rosenzweig C, editor. *Climate Change and Agriculture: Analysis of Potential International Impacts*. American Society of Agronomy, Vol. asapspcl. pp. 259–273.
- Moreno JM, Aguilo E, Alonso S, Cobelas MÁ, Anadón R, et al. (2005) A Preliminary General Assessment of the Impacts in Spain Due to the Effects of Climate Change. Available: http://www.magrama.gob.es/en/cambio-climatico/temas/impactos-vulnerabilidad-y-adaptacion/plan-nacional-adaptacion-cambio-climatico/eval_impactos_ing.aspx. Accessed 2014 May 8.
- Rodriguez-Puebla C, Ayuso S, Frias M, Garcia-Casado L (2007) Effects of climate variation on winter cereal production in Spain. *Clim Res* 34: 223–232.
- Iglesias A, Garrote L, Quiroga S, Monco M (2011) A regional comparison of the effects of climate change on agricultural crops in Europe. *Clim Change* 112: 29–46.
- Iglesias A, Mougou R, Monco M, Quiroga S (2010) Towards adaptation of agriculture to climate change in the Mediterranean. *Reg Environ Chang* 11: 159–166.
- Neumann K, Verburg PH, Siehst E, Müller C (2010) The yield gap of global grain production: A spatial analysis. *Agric Syst* 103: 316–326.
- MAGRAMA (2012) Ministerio de Agricultura, Alimentación y Medio Ambiente (MAGRAMA). MAGRAMA Stat Databases. Available: <http://www.magrama.gob.es/es/estadistica/temas/publicaciones/anuario-de-estadistica/>. Accessed 1 April 2012.
- Lawrimore JH, Menne MJ, Gleason BE, Williams GN, Wuertz DB, et al. (2011) An overview of the Global Historical Climatology Network monthly mean temperature data set, version 3. *J Geophys Res* 116: D19121. Available: <http://doi.wiley.com/10.1029/2011JD016187>. Accessed 1 April 2012.
- World Bank, World Development Indicators (WDI) (2012). ESDS Int Univ Manchester. Available: <http://data.worldbank.org/data-catalog/world-development-indicators/wdi-2012>. Accessed 1 April 2012.
- Lobell DB, Banziger M, Magorokosho C, Vivek B (2011) Nonlinear heat effects on African maize as evidenced by historical yield trials. *Nat Clim Chang* 1: 42–45.
- Berryman A, Turchin P (2001) Identifying the density-dependent structure underlying ecological time series. *Oikos* 92: 263–270.
- Royama T (1992) Analytical population dynamics. London, New York: Chapman & Hall. Springer.
- Ricker WE (1954) Stock and recruitment. *J Fish Res Board Canada* 11: 559–623.
- R Development Core Team (2011) R: A language and environment for statistical computing. R Found Stat Comput Vienna. Available: <http://www.r-project.org/>. Accessed 2014 May 8.
- Bates D, Chambers JM (1991) Nonlinear Models. In: Chambers JM, Hastie TJ, editors. *Statistical Models in S*. Wadsworth & Brooks/Cole, Pacific Grove, California.
- Cameron AG, Windmeijer FAG (1996) R-Squared Measures for Count Data Regression Models With Applications to Health-Care Utilization. *J Bus Econ Stat* 14: 209–220.

34. De la Maza M, Lima M, Meserve PL, Gutierrez JR, Jaksic FM (2009) Primary production dynamics and climate variability: ecological consequences in semiarid Chile. *Glob Chang Biol* 11:116–1126.
35. Liu Z, Yang X, Hubbard K, Lin X (2012) Maize potential yields and yield gaps in the changing climate of Northeast China. *Glob Chang Biol* 86.
36. Bivand RS, Pebesma E, Gómez-Rubio V (2008) *Applied Spatial Data Analysis with R*. New York, NY: Springer New York.
37. Bivand R, Altman M, Anselin L, Assunção R, Berke O, et al. (2013) *spdep: Spatial dependence: weighting schemes, statistics and models*. R package version 0.5-56.
38. Berryman AA (1999) *Principles of population dynamics and their application*. Stanley Thrones (Publishers) Limited.
39. Sun BJ, Van Kooten GC (2013) Weather effects on maize yields in northern China. *J Agric Sci* 1–11.
40. Butler EE, Huybers P (2012) Adaptation of US maize to temperature variations. *Nat Clim Chang* 3: 68–72.
41. Lobell DB, Hammer GL, McLean G, Messina C, Roberts MJ, et al. (2013) The critical role of extreme heat for maize production in the United States. *Nat Clim Chang* 3: 497–501.
42. Lobell DB, Bonfils CJ, Koeppers LM, Snyder MA (2008) Irrigation cooling effect on temperature and heat index extremes. *Geophys Res Lett* 35: L09705.
43. Muchow RC, Sinclair TR, Bennett JM (1990) Temperature and Solar Radiation Effects on Potential Maize Yield across Locations. 82: 338–343.
44. Chen C, Lei C, Deng A, Qian C, Hoogmoed W, et al. (2011) Will higher minimum temperatures increase corn production in Northeast China? An analysis of historical data over 1965–2008. *Agric For Meteorol* 151: 1580–1588.
45. Lobell DB (2007) Changes in diurnal temperature range and national cereal yields. *Agric For Meteorol* 145: 229–238.
46. Peng S, Huang J, Sheehy JE, Laza RC, Visperas RM, et al. (2004) Rice yields decline with higher night temperature from global warming. *Proc Natl Acad Sci U S A* 101: 9971–9975.
47. Mohammed A, Tarpley L (2007) Effects of High Night Temperature on Crop Physiology and Productivity: Plant Growth Regulators Provide a Management Option. *Global Warming Impacts – Case Studies on the Economy, Human Health, and on Urban and Natural Environments*. doi:10.5772/24537.
48. Rosenzweig C, Tubiello FN (1996) Effects of changes in minimum and maximum temperature on wheat yields in the central US A simulation study. *Agric For Meteorol* 80: 215–230.
49. Muchow RC (1990) Effect of high temperature on grain-growth in field-grown maize. *F Crop Res* 23: 145–158.
50. Alward RD, Delling J, Milchunas D (1999) Grassland Vegetation Changes and Nocturnal Global Warming. *Science* (80): 283: 229–231.
51. Katz RW, Brown BG (1992) Extreme events in a changing climate: Variability is more important than averages. *Clim Change* 21(3):289–302.
52. Long SP, Ainsworth EA, Leakey ADB, Nosberger J, Ort DR (2006) Food for thought: lower-than-expected crop yield stimulation with rising CO₂ concentrations. *Science* 312: 1918–1921.
53. Bosello F, Carraro C, De Cian E (2009) An Analysis of Adaptation as a Response to Climate Change. *SSRN Electron J*.

Capítulo 4

4. Interferencia malezas-cultivo

4.1 Introducción

Las malezas compiten con los cultivos por los recursos (agua, luz y nutrientes; [Ziska 2003](#)). Para su control, los agricultores recurren al uso de agroquímicos pero como consecuencia la diversidad de malezas es reducida drásticamente y **los sistemas de cultivo se simplifican**. Esta pérdida de biodiversidad afecta a las **funciones y servicios del agroecosistema** y podrían disminuir tanto la **productividad** del cultivo como su **resiliencia** al cambio climático ([Altieri 1999](#)).

En este estudio analizamos el efecto de la **biodiversidad** del agroecosistema (a través de la **diversidad de la comunidad de malezas**) sobre el rendimiento de los cultivos agrícolas (**soja y maíz**) y su **interacción con la variabilidad climática** que experimentan. Utilizamos un experimento a largo plazo desarrollado en Michigan-EE.UU. que nos permite obtener un amplio gradiente de diversidad de malezas. Evaluamos bajo qué tipo de composición de la comunidad de malezas nos permite obtener un **mayor rendimiento** del cultivo y una **mayor estabilidad** ante las perturbaciones climáticas. Esto nos permitiría proponer medidas de **mitigación y adaptación** al cambio climático mediante la **gestión sustentable de la biodiversidad del agroecosistema**.

El capítulo contiene el artículo “*Weed Diversity Affects Soybean and Maize Yield in a Long Term Experiment in Michigan, USA*”. publicado en la revista *Frontiers In Plant Sciences* (Q1) (ver pag. 4). El material complementario de este artículo se encuentra disponible en el apéndice.

4.2 Weed Diversity Affects Soybean and Maize Yield in a Long Term Experiment in Michigan, USA



Weed Diversity Affects Soybean and Maize Yield in a Long Term Experiment in Michigan, USA

Rosana Ferrero^{1,2*}, Mauricio Lima^{2,3,4}, Adam S. Davis⁵ and Jose L. Gonzalez-Andujar^{1,4}

¹ Departamento Protección de Cultivos, Instituto de Agricultura Sostenible, Consejo Superior de Investigaciones Científicas, Córdoba, Spain, ² Center of Applied Ecology and Sustainability (CAPEs), Pontificia Universidad Católica de Chile, Santiago, Chile, ³ Facultad de Ciencias Biológicas, Pontificia Universidad Católica de Chile, Santiago, Chile, ⁴ Laboratorio Internacional de Cambio Global, (CSIC-PUC), Santiago, Chile, ⁵ Global Change and Photosynthesis Research Unit, Agricultural Research Service (USDA), Urbana, IL, USA

OPEN ACCESS

Edited by:

Urs Feller,
University of Bern, Switzerland

Reviewed by:

Luis Enrique Eguarte,
National Autonomous University of
Mexico, Mexico
Nathaniel Newlands,
Government of Canada, Science and
Technology, Canada

*Correspondence:

Rosana Ferrero
rferrero@ias.csic.es

Specialty section:

This article was submitted to
Agroecology and Land Use Systems,
a section of the journal
Frontiers in Plant Science

Received: 03 December 2016

Accepted: 07 February 2017

Published: 24 February 2017

Citation:

Ferrero R, Lima M, Davis AS and
Gonzalez-Andujar JL (2017) Weed
Diversity Affects Soybean and Maize
Yield in a Long Term Experiment in
Michigan, USA.
Front. Plant Sci. 8:236.
doi: 10.3389/fpls.2017.00236

Managing production environments in ways that promote weed community diversity may enhance both crop production and the development of a more sustainable agriculture. This study analyzed data of productivity of maize (corn) and soybean in plots in the Main Cropping System Experiment (MCSE) at the W. K. Kellogg Biological Station Long-Term Ecological Research (KBS-LTER) in Michigan, USA, from 1996 to 2011. We used models derived from population ecology to explore how weed diversity, temperature, and precipitation interact with crop yields. Using three types of models that considered internal and external (climate and weeds) factors, with additive or non-linear variants, we found that changes in weed diversity were associated with changes in rates of crop yield increase over time for both maize and soybeans. The intrinsic capacity for soybean yield increase in response to the environment was greater under more diverse weed communities. Soybean production risks were greatest in the least weed diverse systems, in which each weed species lost was associated with progressively greater crop yield losses. Managing for weed community diversity, while suppressing dominant, highly competitive weeds, may be a helpful strategy for supporting long term increases in soybean productivity. In maize, there was a negative and non-additive response of yields to the interaction between weed diversity and minimum air temperatures. When cold temperatures constrained potential maize productivity through limited resources, negative interactions with weed diversity became more pronounced. We suggest that: (1) maize was less competitive in cold years allowing higher weed diversity and the dominance of some weed species; or (2) that cold years resulted in increased weed richness and prevalence of competitive weeds, thus reducing crop yields. Therefore, we propose to control dominant weed species especially in the years of low yield and extreme minimum temperatures to improve maize yields. Results of our study indicate that through the proactive management of weed diversity, it may be possible to promote both high productivity of crops and environmental sustainability.

Keywords: climate change, maize, long-term experiment, soybean, weed diversity, nonlinearity, crop management

INTRODUCTION

Feeding more people sustainably is among humanity's biggest challenges in the next century (Godfray et al., 2010). Until now, agricultural expansion and intensification has had tremendous impacts including environmental degradation from loss of biodiversity and habitat, chemical inputs into waterways and deterioration of soil health (Foley et al., 2011). As agricultural production must increase by at least 60% before 2050 to meet increasing population and consumption trends (Alexandros and Bruinsma, 2012), doing so in ways that do not compromise environmental integrity or public health will be a great challenge (Tilman et al., 2002). One promising approach to sustainable intensification is to assess, and make use of agroecosystem services that enhanced biodiversity might provide (Vandermeer et al., 1998; Swift et al., 2004; Cardinale et al., 2012; Robertson et al., 2014). However, we must first seek to understand how agricultural systems are related to biodiversity, to develop new strategies that take advantage of ecological interactions within agricultural systems (Loreau et al., 2001). Here we explore the potential effects of diversifying weed community systems as a means of controlling harmful species while simultaneously enhancing desirable agroecosystem services. Opportunities to develop strategies of weed community management based on differences in weed diversity exist to enhance crop production and producing a more sustainable agriculture.

Weeds compete with crop species, causing total crop losses in some cases, but also play an important role in supporting agroecosystem functions and services. For example, weeds can enhance soil and water conservation, nutrient cycling, pollination activity, provide food sources for animals and insects, and host biological control agents (Altieri, 1999; Marshall and Brown, 2003). Recent findings suggest the importance of weed diversity within agroecosystems, and highlight new options for weed management (Franke and Lotz, 2009; Petit and Boursault, 2010) that balance yield and weed diversity conservation. However, very little is known about how weed community diversity is related to crop yield and its temporal variability. Mechanistic studies are needed to make reliable recommendations (Davis et al., 2005), and such studies should take into account several important considerations. First, climate change and climate variability may underlie and confound the diversity–productivity relationship (Vilà et al., 2005; Belote et al., 2011). Second, the effects of biodiversity on ecosystem functioning appear to vary over time and space (Mittelbach et al., 2001; Symstad et al., 2003). Finally, management inferences drawn from such investigations should strike a balance between adequate weed control and the requirements for biodiversity and more sustainable production methods (Marshall and Brown, 2003).

Abbreviations: Large crabgrass, *Digitaria sanguinalis* L. DIGSA; red clover, *Trifolium pratense* L. "Michigan Mammoth Red" TRIPR; garden yellowrocket, *Barbarea vulgaris* R. Br. BARVU; shepherd's purse, *Capsella bursa-pastoris* L. CAPBU; giant foxtail, *Setaria faberi* L. SETFA; lambsquarters, *Chenopodium album* L. CHEAL; common dandelion, *Taraxacum officinale* TAROF; velvetleaf, *Abutilon theophrasti* Medik ABUTH; soybean, *Glycine max* [L.] Merr.; and maize, *Zea mays* L.

Here we study maize and soybean yield in the Main Cropping System Experiment (MCSE) from 1996 to 2011 at the Long-Term Ecological Research site at the W. K. Kellogg Biological Station (KBS LTER) located in southwest Michigan. KBS is the only LTER site focused on row-crop agriculture and represents one of the most extensive and important agroecosystem types (Smith et al., 2008) in the USA that is managed intensively with well-known environmental impacts (Robertson and Hamilton, 2015). Extreme heat limits maize and soybean production in the region (Schlenker and Roberts, 2009; Mourtzinis et al., 2015; Leng et al., 2016) through increased water stress (Lobell and Asner, 2003; Lobell et al., 2013) and crop density (Lobell et al., 2014; Ort and Long, 2014). However, increases in minimum air temperature could be more significant in their effect on maize (Muchow et al., 1990; Chen et al., 2011; Grassini et al., 2011; Hatfield et al., 2011). Among US expenditures to ameliorate biotic stresses in agriculture, weeds are the most costly.

It has been suggested that we need to know how to manage cropland for an array of ecosystem services to balance or reduce the negative impacts of agricultural production, an area of research largely unexplored (Robertson and Hamilton, 2015). In this study, we evaluate the role of weed diversity in supporting agricultural productivity and sustainability in cropping systems. For this purpose we will use an analytical tool we have recently proposed based on population dynamic theory to investigate crop yield oscillations (Ferrero et al., 2014). While not a true population in the reproductive sense, cropping systems obey similar rules as other dynamic systems, both natural and engineered (Ferrero et al., 2014). This method allows us to include logical explanations of the possible effects of weed community diversity on the rates of yield increase under climate perturbations.

MATERIALS AND METHODS

Empirical Databases and Data Preprocessing

A time series of crop, weed, and site climate data were obtained with permission from the Main Cropping System Experiment (MCSE) of the Kellogg Biological Station's Long-Term Ecological Research (KBS-LTER) site in southwest Michigan, USA (Smith et al., 2008; <http://lter.kbs.msu.edu/datatables/>). From 1996 to 2011, the annual cropping systems were maize (*Zea mays* L.)–soybean (*Glycine max* [L.] Merr.)–winter wheat (*Triticum aestivum* L.) rotations under four different management regimes (Figure 1). One system (T1) was managed conventionally on the basis of current cropping practices in the region with high external chemical input and tillage. A second (T2) was managed as no-till system, otherwise identical to the conventional system (high external chemical input but no tillage). A third (T3) was managed as a reduced-input system, receiving one-third of the conventional system's chemical inputs. A fourth system (T4) was managed organically with no external chemical inputs. The T3 and T4 systems were tilled in the same way as T1, but used winter cover crops of red clover or annual rye to provide additional nitrogen. Weed control was accomplished with herbicides (glyphosate) in T1, T2, and T3 (before 2009) and




FIGURE 1 | Observed yield numerical fluctuations (kg/ha) of the two crop species: soybean (*Glycine max* [L.] Merr.) and maize (*Zea mays* L.). Loess smoothed fit curves with confidence regions are showed.

through additional physical cultivation in the T3 and T4 systems. Starting in 2009 (for soybean) and 2011 (for maize), transgenic crop cultivars were used, with glyphosate resistance and (for maize) resistance to European corn borer (*Ostrinia nubilalis*) and root worm (*Diabrotica* spp.). No transgenic crop cultivars were used in T4.

Each management system was replicated in 6 blocks of 1 ha in a randomized complete block design. Crop yields (i.e., crop kernel/seed harvested at crop harvest in kg/ha) were determined annually by harvesting each block at standardized moisture for maize 15.5% and wheat/soybean 13%. In this paper grain yield of maize and soybean were selected because they share a similar growing season, critical to our comparison of weed diversity and climate variability effects on crop production for similar agricultural situations. Maize (grown in 1996, 1999, 2002, 2005, 2008, and 2011) and soybean (grown in 1997, 2000¹, 2003, 2006, and 2009) were harvested in November and October, respectively (see Table S1).

Weed biomass at the species level was measured at peak biomass for a given treatment with six replications (blocks). Plants were hand harvested using a 1 m² quadrat at each sampling station before harvest of the crop plants. Weed biomass was separated to the species level, dried to constant weight at 65°C, and dry biomass for each species recorded. Productivity data for plants other than target crops (i.e., weeds) were obtained as dry biomass m⁻². We argue that crop biomass is more adequate than counts of individuals of variable sizes for measure plant abundance (Oksanen, 2013). For each crop, we derived the growing season average weed community richness and diversity across all samples using Richness, Shannon–Wiener, Simpson's, Inverse Simpson, *J'*- and *E*-evenness indices. Details of how biodiversity indices were obtained are in the supplementary information, Supplementary material (Appendix A1). We used the *Biodiversity R* package (Kindt and Coe, 2005) implemented

¹There were missing data for weeds in the year 2000.

in the R CRAN environment (R Development Core Team, 2011) and applied the “diversityresult” function.

Daily precipitation (mm) and air temperature (°C) values were obtained from the KBS LTER Site Weather Station located in the experimental site (<http://lter.kbs.msu.edu/datatables/>). For each crop and sample, we derived the growing season average temperature (*tM*), the average maximum (*tmax*), and minimum (*tmin*) temperature, the average rainfall (*precM*) and extremes values (*tMax*, *tMin*, and *precMax*). Maize was planted early May and harvested late September; and soybean, planted late May and harvested early October.

Diagnosis and Models of Crop Yield Dynamics

Crop yield dynamics are the result of the combined effect of internal (ecophysiological and biophysical traits related to resource acquisition and use, and the trade-offs between them that constrain crop production) and external (e.g., weed diversity and climate perturbations) processes (Ferrero et al., 2014). To understand how these processes may determine crop yield fluctuations, we analyze both as a general model based on the rates of yield increase.

Detection of Internal Processes

To minimize the influence of slowly changing factors (non-climatic influences) such as crop management and improvement in crop genetics, we detrended crop yield data by a quadratic trend (see Lobell et al., 2011b). Then, to generate a stationary time series we computed the first difference log-yield series (as in Lobell et al., 2011a,b). We used the difference in values for a given crop from one time step to the next value (in log-scale) and called it the crop yield rate of increase, $R_t = Y_t - Y_{t-1}$.

A crop yield model incorporating both internal and external processes may be depicted as $R_t = f(Y_{t-d}, Z_{t-d}, \epsilon_t)$, where d denotes the number of lags to be included and Z_{t-d} is the weed diversity and/or climatic conditions (with lags $d = 0$ and 1). We used the Royama-type non-linear log-model (Ricker, 1954; Royama, 1992) as our form for the function f to fit time series data:

$$R_t = r_{\max} - \exp(aY_{t-d} + c) \quad (1)$$

where Y_{t-d} represent crop yield at time $t - d$, r_{\max} is a positive constant representing the maximum increase in crop yields (and is estimated as the maximum value observed from the data), c is a measure of the ratio between supply and demand of limiting resources and a is a shape parameter representing the non-linear interaction strengths (i.e., functional responses). To estimate the order of the process d we used the partial rate correlation function (*PRCF*; the partial correlation coefficients between R_t and Y_{t-d} ; Berryman and Turchin, 2001). This function is flexible enough to detect a wide range of system behaviors and includes a biologically realistic property: the crop performance is bounded (Royama, 1992), because no crop can produce an infinite yield value, there must be an upper bound in R_t in (1). Because in this model the three parameters r_{\max} , c , and a have an explicit biological interpretation we can include external perturbations in

each parameter using the framework of Royama (1992). Thus, we can build biological hypotheses about the effects of climate and weed diversity on crop yields, and evaluates the consequences on the nontrivial root $R_t = K$ (its equilibrium or yield potential) and the slope² at the yield potential, which reflects the stability of the dynamic.

External Perturbations: Weed Diversity and Climate

External perturbations could translate the conditional function curve (Equation 1) with dynamic consequences (Appendix A2). We used the function $\text{blog}(Z_{t-d})$ to represent perturbations of an external factor Z over a limited range of variation (Lobell and Burke, 2010) in each parameter of (1). In this manner, changes in c have non-additive effects on crop growth rates (lateral model, sensu Royama, 1992):

$$R_t = r_{\max} - \exp(aY_{t-d} + c + b \log(Z_{t-d})) \quad (2)$$

where Z_{t-d} is the weed diversity and/or climatic conditions (with lags $d = 0$ and 1). For example, precipitation may influence the temporal variation of water availability, a limiting resource for crops. Here an external factor affects the yield potential but not its stability through changes in the amplitude or period of oscillation. The stability of the yield potential point is determined by the slope of the function in its vicinity (estimated by the product of r_{\max} and a): the steeper the slope, the less stable the equilibrium (Berryman, 1999).

Simple additive effects occur when an external perturbation changes the maximum capacity of response of the crop (changes in r_{\max} ; vertical model, sensu Royama, 1992):

$$R_t = r_{\max} - \exp(aY_{t-d} + c) + b \log(Z_{t-d}) \quad (3)$$

That is, for example, when during warmer years the crop acquires less resources and produces less seeds than during colder years. Variation in this parameter could modify the equilibrium point and could alter its stability.

Changes in the nonlinearity parameter a represent a different functional response of growth rates to an external factor (non-linear model, sensu Royama, 1992):

$$R_t = r_{\max} - \exp((a + b \log(Z_{t-d}))Y_{t-d} + c) \quad (4)$$

Here, for example, maximum temperature would affect water availability for crops according to some function for low temperature values, and according to another function for high values of temperature. This also could affect both the equilibrium point and its stability.

Finally, we deal with combined effects and non-independence of predictors by including interaction terms in each of these models ($\text{blog}(Z_{t-d}^1/Z_{t-d}^2)$).

In Appendix A2 we demonstrate how changes in r_{\max} and c translate the conditional function curve $R_t = f(Y_{t-d}, Z)$ moving it vertically and laterally, respectively, but do not influence its relative shape (Royama, 1992). However, perturbations in

²The stability of the equilibrium point is determined by the slope of the R -function in the vicinity of equilibrium (r_{\max}^*a): the steeper the slope, the less stable the equilibrium (Royama, 1992).

a influence the relative shape of the conditional production curve.

Model Fitting

We fitted Equations 2–4 using nonlinear least squares regressions with the *nls* library of the *R* statistical computing environment (Bates and Chambers, 1991; R Development Core Team, 2011). A model selection criterion was used to rank competing models and to weigh the relative support for each one. We used the multi-model selection methods described by Burnham et al. (2002) to compare a suite of candidate models using Akaike weights, w_i . Akaike weights can be interpreted as the probability that model i is the best one for the observed data, given the candidate set of models (Johnson and Omland, 2004). We report confidence sets of models fitted to each data set, that is, the smallest subset of candidate models for which the w_i sum to 0.99. We reported also the pseudo R^2 measures based on the deviance residual (Cameron and Windmeijer, 1996).

Analysis of Temporal Diversity

When we detected an association between crop yield and weed community diversity, we identified the weed species that contribute most to these diversity indexes to focus on more important components of the weed community. Weed database were reduced to eliminate rare species (<5% of a sample in entire data set) and avoid unduly large influence on the analysis. Pearson's correlation coefficients were computed between the weed diversity indices and the Hellinger-transformed weed species data (a standardization method; Legendre and Gallagher, 2001). The large positive/negative correlations identified the weed species that contributed more to the observations with large/small weed diversity indices. We used a threshold of $|r| > 0.4$ for inclusion in correlations of interest. These correlations could not be tested for significance because the diversity indices were not independent from the species data from which were computed.

RESULTS

Detrended time series of soybean and maize yield exhibited first-order negative feedback structures [$PRCF(1)$] as the most important component of yield growth rate (Figure S1). Due to these stabilizing feedbacks, both crops exhibited stable approaches to equilibrium (regular oscillations). Internal processes appeared to contribute more to the dynamics of soybean ($R^2 = 0.76$, $AICc = 61.67$) than of maize ($R^2 = 0.49$, $AICc = -88.26$; Table 1). Model selection retained 6 plausible models for soybean and 4 plausible models for maize (i.e., a 99% confidence set of models; Table 1). For soybean, all retained models included a positive weed community diversity effect (richness, evenness and diversity measures) on r_{\max} , which improved the explained variance by 20% ($R^2 = 0.96$, $AICc = -64.27$ for the best model; Table 1, Figure 2, and Figure S2). Therefore, weed diversity affects the rate of crop yield change independently of the current yield level (additive). Although the rate of yield change increased, the dynamics of soybean production maintained a stable and damped approach

TABLE 1 | Optimal crop yield models for maize (ZeaL) and soybean (GlycL) production using the exponential form of logistic growth.

Crop	Fit	Variable	r_{\max}	a	c	b	AIC_c	ΔAIC_c	w_i	R^2
ZeaL	L	tMin	1.20	0.37**	-5.49**	12.58**	-22.03	0	0.97	0.80
	L	tmax/tMin	1.20	0.41**	-5.99**	10.32**	-12.12	9.91	0.01	0.78
	L	Shannon/tMin	1.20	0.53**	-4.76**	11.87**	-11.83	10.19	0.01	0.84
	L	Simpson/tMin	1.20	0.51	-4.55**	12.85**	-11.76	10.26	0.01	0.84
	P		1.20	0.93**	-7.91**		88.26	87.27	0	0.49
GlycL	V	Evenness	0.97	0.63**	-4.09*	0.31*	-64.27	0	0.22	0.96
	V	Simpson	0.97	0.64**	-4.15*	0.31*	-64.11	0.16	0.20	0.96
	V	Shannon	0.97	0.65**	-4.19*	0.30*	-63.98	0.30	0.19	0.96
	V	Invsimp	0.97	0.66**	-4.27*	0.30*	-63.73	0.54	0.17	0.96
	V	Jevenness	0.97	0.64**	-4.11*	0.31*	-63.15	1.12	0.13	0.97
	V	Richness	0.97	0.71**	-4.80**	0.26*	-62.34	1.93	0.08	0.96
	P		0.97	1.95**	-15.23**		61.67	125.95	0	0.76

The best models were chosen by using multi-model selection methods described by Burnham et al. (2002) that compare a suite of candidate models using Akaike weights. We evaluated our basic model with internal processes (P) and the external perturbations of their parameters: r_{\max} , maximum finite reproductive rate (vertical model, V), a non-linearity coefficient (non-linear model, N), c , the ratio between demand and offer of limiting resources (lateral model, L); with b coefficients for different external effects. AIC_c , corrected Akaike information criterion, ΔAIC_c , delta AIC_c , and w_i , Akaike weights of a set of selected models, and R^2 , pseudo-coefficient of determination. Further description of the variables included in the models are given under "Materials and Methods" (here minimum -tMin-, mean -tM- and average maximum -tmax- temperature for growing season and weed community diversity indices -Shannon and Simpson indices-).

* $p < 0.01$; ** $p < 0.05$.

to equilibrium when weed diversity was taken into account (Table 2).

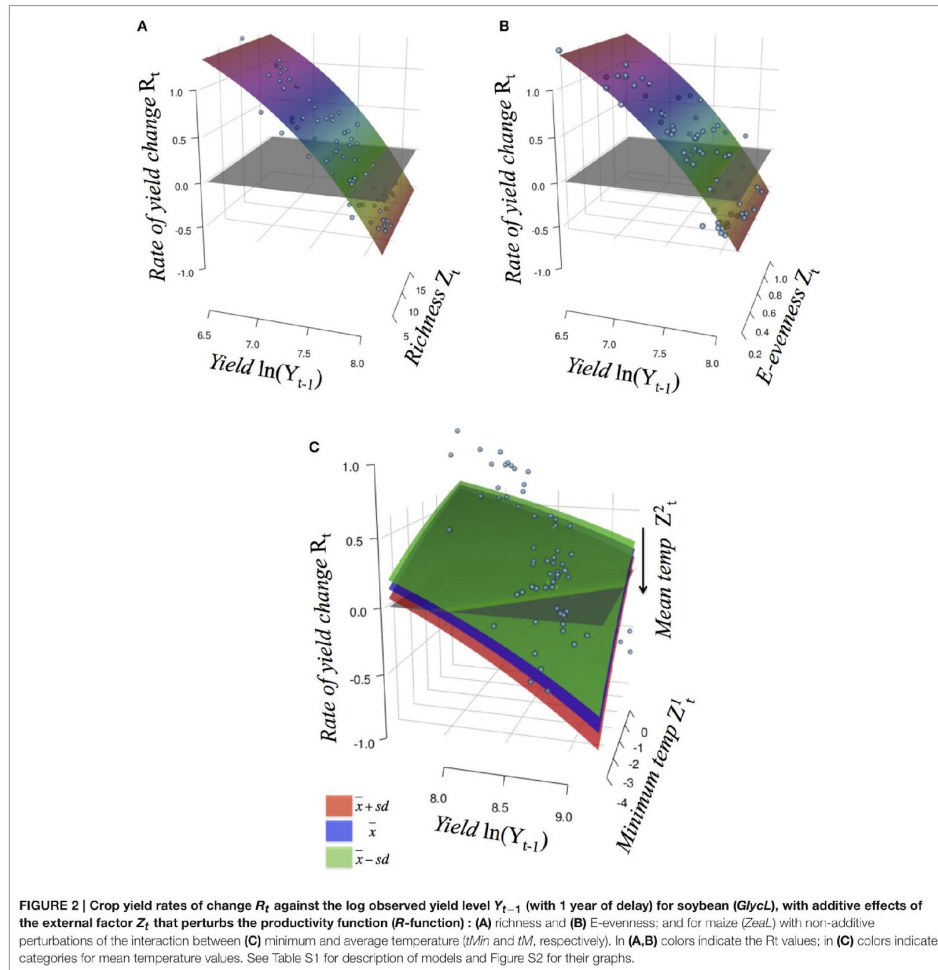
The rate of change of soybean growth yields was decelerated as the agro-ecosystem moved to a more diverse system (holding yield fixed; partial derivative $\partial R_i / \partial Z = b/Z$; for example Figure 3 for Evenness). This is consistent with the low values of percentage of increase found for the model parameters (Table 2). For soybean, high weed Evenness values were often related to a small number of weed species ($r = -0.73$; Figure S3). Red clover (*Trifolium pratense* L., "Michigan Mammoth Red," TRIPR; Figure S4) biomass was positively correlated with the inverse Simpson index in reduced input and organic plots. Weed richness was positively correlated with garden yellowrocket (*Barbarea vulgaris* R. Br., BARVU) and shepherd's purse biomass (*Capsella bursa-pastoris* L., CAPBU), both winter annuals and rare species; negatively correlated with large crabgrass (*Digitaria sanguinalis* L., DIGSA; a summer annual species) biomass and positively but less to giant foxtail biomass (*Setaria faberi* L., SETFA; a highly adaptable, quick-recruiting summer annual species).

For maize, the 4 best-performing models included negative effects on c of extreme minimum temperature (tMin) through interaction with: average temperature (tM; $w_i = 0.97$), average maximum temperature (tmax; $w_i = 0.01$), Shannon diversity index (shannon; $w_i = 0.01$) and Simpson diversity index (simpson; $w_i = 0.01$); with more than 78% of variance explained (and $R^2 = 0.80$, $AIC_c = -22.03$ for the best model; Table 2). As an interaction effect is present, the impact of extreme minimum temperature depends on the level of the other variable. All models suggested that less negative minimum temperatures act to increase maize production, whereas mean and maximum temperature, as well as weed diversity, constrains this yield potential (Figure 2 and Figure S2).

For maize, weed Shannon, and Simpson diversity was negatively correlated to weed evenness ($r = -0.36$ and -0.30 , respectively; Figure S3). As show in Figure S5, weed diversity was positively correlated with common dandelion (*Taraxacum officinale*, TAROF; winter perennial species), lambsquarters (*Chenopodium album* L., CHEAL; summer annual species) and velvetleaf (*Abutilon theophrasti* Medik, ABUTH; summer annual species) biomass. All are important weeds of field maize production systems in the U.S. Corn Belt.

DISCUSSION

In our long-term analysis (1996–2011) we showed that the combined effects of internal and external processes involving weed diversity were strongly associated with soybean and maize yield fluctuations. Internal processes included ecophysiological and biophysical traits related to resource acquisition and use, and the trade-offs between them (by first-order negative feedbacks) that constrain crop production and produced rapid and stable yield fluctuations, consistent with our previous study of maize in Spain (Ferrero et al., 2014). The regulation of crop production appears to be stronger in soybean (76%) than maize (49%; "P" line in Table 1) and therefore maize seems to be more sensitive to environmental variation. Increases in weed diversity were significantly associated with soybean and maize yield, but these relationships were crop-species specific. In soybean, yield increased additively with weed diversity, whereas increasing weed diversity constrained maize yield non-additively under freezing temperatures. For soybean this result implies that under higher weed diversity, the crops additively improved its maximum capacity of response (changes in r_{\max}). Namely, during years of higher weed diversity, soybean acquires more resources and/or produces more seeds than during years of



lower weed diversity, thus affecting the intrinsic capacity of increase in soybean yields (r_{max} ; a species-specific adaptation). Under conditions favoring high weed diversity, soybean may be more adapted to resist yield decline due to negative environmental effects. For example, weeds could alter the crop environment changing the light interception, critical weed-free period for soybean or through allelopathic effects (Morvillo et al., 2011). Identifying which functional traits underlie weed diversity effects, and also characterizing these traits in relation


to the ecology of each crop, may be an important area for future research.

This positive association between soybean yield and weed diversity appears particularly relevant to low-diversity agroecosystems, typical of grain production systems in the northern Corn Belt of the USA. The increases in crop production accelerated at low weed diversity values (Table 2, Figure 3), and then, in low-diversity plots small increases in weed diversity are sufficient to enhance crop productivity. Because the moderate

TABLE 2 | Descriptive statistics for climate and weed diversity variables for maize (*ZeaL*) and soybean (*GlycL*) production, where M, mean; SD, standard deviation; R, range; N, size and the percent of change in model parameters: for slope (it is estimated by $r_{max} \cdot a$), yield potential K , and the maximum increase in crop yields r_{max} .

Crop	Fit	Variable	M	SD	R	N	slope	% slope	% r_{max}	% K
ZeaL	L	tM/tMin	-14.18	252.60	(-479.19; 388.53)	118	0.44	0.00	0.00	-16.30
	L	tmax/tMin	-17.31	335.89	(-633.27; 521.03)	118	0.49			-8.28
	L	Shannon/tMin	1.21	18.06	(-45.07; 41.03)	92	0.64			-8.07
	L	Simpson/tMin	0.46	8.53	(-20.02; 15.85)	92	0.61			-8.18
	P					118	1.12			
GlycL	V	Evenness	0.52	0.25	(0.16; 1)	71	1.51	0.11	0.11	0.02
	V	Simpson	0.40	0.23	(0; 0.83)	71	1.54	0.11	0.11	0.02
	V	Shannon	0.78	0.46	(0; 2.07)	71	1.53	0.26	0.26	0.05
	V	Invsimp	1.99	0.89	(1; 5.90)	71	1.53	0.60	0.60	0.12
	V	Jevenness	0.51	0.21	(0.04; 0.99)	69	1.54	0.12	1.22	0.02
	V	Richness	5.83	3.80	(1; 18)	71	1.56	1.86	1.86	0.33
	P					94	1.89			

See **Table 1** for more details.



correlation between weed evenness and the others diversity indexes, we could conclude that the effect of weed community is not only due to species identity but also to species interactions (i.e., complementarity and facilitation) maybe as supporters of reliable ecosystem functioning (Naeem, 2008). Put another way, the hyperbolic relationship we observed indicated that each additional species lost from our agroecosystem had a progressively greater negative impact on crop production.

Therefore, the greatest crop production risks were in the least diverse systems. Also, weed diversity effects on soybean production did not change the stability properties of crop yield dynamics (amplitude and periodicity) and therefore did not provide support for the predictions of lower crop yield stability proposed by models of resource competition (Tilman, 1999). The potential benefits that weeds provide to cropping systems may help identify opportunities to harness their beneficial effects and to develop better weed management strategies (Smith et al., 2011). We hypothesized that the improved capacity to achieve high levels of productivity would promote an economically profitable system with a reduced need for external inputs as was proposed for increasing cropping system diversity (Davis et al., 2012). We call for future experiments explicitly to evaluate these potential links.

For maize, interaction terms of extreme minimum temperature with mean and maximum temperature, as well as weed diversity indices, negative, and non-additively affected maize yield through changes in the supply and/or demand of some limiting resources (changes in c ; **Table 1**, **Figure 2**, and **Figure S2**). This implies that the effects of these variables must be considered in conjunction with constraints on the yield potential of maize, and indicate that the negative impacts of extreme minimum temperature increase with increasing levels of tM or $tmax$, and weed *Shannon* and *Simpson* diversity. The first finding is in agreement with a previous study on US maize where there was a large negative response of maize yields to increased temperature range, as a result of greater water and heat stress during hot days and crop injury or death on freezing night temperatures (Lobell, 2007). This result also supports previous studies showing that frost periods at either end of the growing season were crucial for maize production (Miedema, 1982; Muchow, 1990; Lobell, 2007; Chen et al., 2011; Ferrero et al., 2014) at this high latitude site. The second finding indicates that negative effects of weed diversity on maize yield are mediated through decreases in the minimum temperature.

Including the interactions between exogenous factors allowed us to model concurrent and compound effects on crop yields. As a result, we were able to detect that the impact of weed diversity on crop yields was more pronounced when coupled with lower temperatures (cooler nights). This result has major implications for the accuracy and reliability of crop yield forecasting models and decision-support, because it might not have been revealed (or confused) if we had only analyzed the exogenous factors separately. In explaining the above results, we suggest that: (1) maize was less competitive in cold years allowing higher weed diversity and the dominance of some weed species; or (2) that cold years resulted in increased weed richness and prevalence of competitive weeds, thus reducing crop yields. Further studies are necessary to clarify these mechanisms, although our findings indicate the need to control undesirable, highly competitive species like common dandelion, lambsquarters, and velvetleaf within a maize crop. Finally, our results differ somewhat from other studies in which plant species diversity impacts on crop yields were analyzed with respect to crop sequence diversification; for example, Smith et al. (2008) indicated that maize grain yield increased linearly in response to the diversity of the system, specifically the number of crops in the rotation. However, here we have found that small changes in weed diversity and minimum temperature interaction could exert big changes in maize production when yield levels are low, due to nonlinear responses. Such information can aid crop yield forecasting, preventing overly optimistic predictions by recognizing that these forecasting tools may not be equally effective at low and high crop yield levels.

Our findings complement the results from previous studies that assessed the impact of diversity on grassland productivity (Hector et al., 1999; Tilman et al., 2001, 1996) for two reasons. First, by improving the debate over biodiversity and ecosystem functioning, showing the role of weed diversity on crop productivity. We suggest that weed diversity could also play an important role in supporting agroecosystem functions and services in crop systems. Second, differentiating additive and non-additive effects that act through different potential mechanisms. We found a higher soybean rate of yield increase (and its potential yield) for weed communities more evenness, and that under lower temperatures (cooler nights) weeds could harm maize when it is at high yield levels.

CONCLUSIONS

The results presented here show that the conditions underlying weed diversity in soybean and maize fields can lead to significant increases in crop yields. The new analytical approach presented here elucidates how crops are related to weed biodiversity loss or gain, and detects the minimum level of biodiversity associated

with stable, bountiful crop yields. A better understanding of little-observed structural properties of agroecosystems, such as the stability of yield dynamics and nonlinear responses to weed diversity and climate variability observed in this analysis, can help guide management practices to maintain crop productivity under increased environmental variability through judicious management of biodiversity in agroecosystems. While testing the specific mechanisms is beyond the scope of our analysis, our results should motivate future studies to evaluate these potential links.

DATA ACCESSIBILITY

Crop yield data are available at <http://lter.kbs.msu.edu/datatables/51> and correspond to the rotation of 3 crops (maize-soybean-winter wheat), with 7 treatments (T1 ... T7) of which we only use the first 4: traditional management (T1), conservation management (T2 and T3) and ecological management (T4). Each treatment has 6 replicates. Weed biomass data (<http://lter.kbs.msu.edu/datatables/40>), daily precipitation and air temperature (<http://lter.kbs.msu.edu/datatables/7>) were also obtained for each treatment and replicate.

AUTHOR CONTRIBUTIONS

All authors conceived the ideas, designed methodology and contributed critically to the drafts and gave final approval for publication; AD collected the data; RF analyzed the data and led the writing of the manuscript.

ACKNOWLEDGMENTS

RF gratefully acknowledges receipt of a grant from the Fundación Carolina. JG and RF were supported by FEDER (European Regional Development Funds) and the Spanish Ministry of Economy and Competitiveness funds (AGL2012-33736 and AGL2015-64130-R). RF and ML acknowledge financial support from Center of Applied Ecology & Sustainability (CAPES; CONICYT FB 0002-2014). We are grateful to Laboratorio Internacional en Cambio Global (LINCGlobal) for their support. Finally, we extend our sincere appreciation to the W.K. Kellogg Biological Station Long Term Ecological Research site for access to the time series data on crop yield. Support for this research was also provided by the NSF Long-Term Ecological Research Program at the Kellogg Biological Station and by Michigan State University AgBioResearch.

SUPPLEMENTARY MATERIAL

The Supplementary Material for this article can be found online at: <http://journal.frontiersin.org/article/10.3389/fpls.2017.00236/full#supplementary-material>

REFERENCES

- Alexandratou, N., and Bruinsma, J. (2012). *World Agriculture Towards 2030 / 2050: The 2012 Revision*. Rome: FAO ESA Working Paper.
- Altieri, M. A. (1999). The ecological role of biodiversity in agroecosystems. *Agric. Ecosyst. Environ.* 74, 19–31. doi: 10.1016/S0167-8809(99)00028-6
- Bates, D., and Chambers, J. M. (1991). "Nonlinear Models," in *Statistical Models in S*, eds J. M. Chambers and T. J. Hastie (Pacific Grove, CA: Wadsworth & Brooks/Cole), 421–454.
- Belote, R. T., Pringle, S., Jones, R. H., Fitzpatrick, M., and de Beurs, K. (2011). Forest productivity and tree diversity relationships depend on ecological context within mid-Atlantic and Appalachian forests (USA). *For. Ecol. Manage.* 261, 1315–1324. doi: 10.1016/j.foreco.2011.01.010
- Berryman, A. A. (1999). *Principles of Population Dynamics and Their Application*. Cheltenham, UK: Stanley Thrones (Publishers) Limited.
- Berryman, A., and Turchin, P. (2001). Identifying the density-dependent structure underlying ecological time series. *Oikos* 92, 265–270. doi: 10.1034/j.1600-0706.2001.920208.x
- Burnham, K., Anderson, D., and Diggle, J. (2002). *Model Selection and Multimodel Inference: A Practical Information-Theoretic Approach*. New York, NY: Springer.
- Cameron, A. C., and Windmeijer, F. A. G. (1996). R-squared measures for count data regression models with applications to health-care utilization. *J. Bus. Econ. Stat.* 14, 209–220. doi: 10.1080/07350015.1996.10524648
- Cardinale, B. J., Duffy, J. E., Gonzalez, A., Hooper, D. U., Perrings, C., Venail, P., et al. (2012). Biodiversity loss and its impact on humanity. *Nature* 486, 59–67. doi: 10.1038/nature11148
- Chen, C., Lei, C., Deng, A., Qian, C., Hoogmoed, W., and Zhang, W. (2011). Will higher minimum temperatures increase corn production in Northeast China? An analysis of historical data over 1965–2008. *Agric. For. Meteorol.* 151, 1580–1588. doi: 10.1016/j.agrformet.2011.06.013
- Davis, A., Renner, K., and Gross, K. (2005). Weed seedbank and community shifts in a long-term cropping systems experiment. *Weed Sci.* 53, 296–306. doi: 10.1614/WS-04-182
- Davis, A. S., Hill, J. D., Chase, C. A., Johanns, A. M., and Liebman, M. (2012). Increasing cropping system diversity balances productivity, profitability and environmental health. *PLoS ONE* 7:e47149. doi: 10.1371/journal.pone.0047149
- Ferrero, R., Lima, M., and Gonzalez-Andujar, J. (2014). Spatio-temporal dynamics of maize yield water constraints under climate change in Spain. *PLoS ONE* 9:e98220. doi: 10.1371/journal.pone.0098220
- Foley, J. A., Ramankutty, N., Brauman, K. A., Cassidy, E. S., Gerber, J. S., Johnston, M., et al. (2011). Solutions for a cultivated planet. *Nature* 478, 337–342. doi: 10.1038/nature10452
- Frank, A., and Lotz, L. (2009). The role of arable weed seeds for agroecosystem functioning. *Weed Res.* 49, 131–141. doi: 10.1111/j.1365-3180.2009.00692.x
- Godfray, H. C. J., Beddington, J. R., Crute, I. R., Haddad, L., Lawrence, D., Muir, J. F., et al. (2010). Food security: the challenge of feeding 9 billion people. *Science* 327, 812–818. doi: 10.1126/science.1185383
- Grassini, P., Thorburn, J., Burr, C., and Cassman, K. G. (2011). High-yield irrigated maize in the Western US Corn Belt: I. On-farm yield, yield potential, and impact of agronomic practices. *Field Crops Res.* 120, 142–150. doi: 10.1016/j.fcr.2010.09.012
- Haftfield, J. L., Boote, K. J., Kimball, B. A., Ziska, L. H., Izaurralde, R. C., Ort, D., et al. (2011). Climate impacts on agriculture: implications for crop production. *Agron. J.* 103, 351–370. doi: 10.2134/agronj2010.0303
- Hector, A., Schmid, B., Beierkuhnlein, C., Caldeira, M. C., Diemer, M., Dimitrakopoulos, P. G., et al. (1999). Plant diversity and productivity experiments in European grasslands. *Science* 286, 1123–1127. doi: 10.1126/science.286.5442.1123
- Johnson, J. B., and Omland, K. S. (2004). Model selection in ecology and evolution. *Trends Ecol. Evol.* 19, 101–108. doi: 10.1016/j.tree.2003.10.013
- Kindt, R., and Coe, R. (2005). *Tree Diversity Analysis: A Manual and Software for Common Statistical Methods for Ecological and Biodiversity Studies*. Nairobi: World Agroforestry Centre (ICRAF).
- Legendre, P., and Gallagher, E. (2001). Ecologically meaningful transformations for ordination of species data. *Oecologia* 129, 271–280. doi: 10.1007/s004420100716
- Leng, G., Zhang, X., Huang, M., Asrar, G. R., and Leung, L. R. (2016). The role of climate covariability on crop yields in the conterminous united states. *Sci. Rep.* 6:33160. doi: 10.1038/srep33160
- Lobell, D. B. (2007). Changes in diurnal temperature range and national cereal yields. *Agric. For. Meteorol.* 145, 229–238. doi: 10.1016/j.agrformet.2007.05.002
- Lobell, D. B., and Asner, G. P. (2003). Climate and management contributions to recent trends in US agricultural yields. *Science* 299:1032. doi: 10.1126/science.1078475
- Lobell, D. B., Bänziger, M., Magorokosho, C., and Vivek, B. (2011a). Nonlinear heat effects on African maize as evidenced by historical yield trials. *Nat. Clim. Change* 1, 42–45. doi: 10.1038/nclimate1043
- Lobell, D. B., and Burke, M. (2010). *Climate Change and Food Security: Adapting Agriculture to a Warmer World*. Dordrecht: Springer.
- Lobell, D. B., Hammer, G. L., McLean, G., Messina, C., Roberts, M. J., and Schlenker, W. (2013). The critical role of extreme heat for maize production in the United States. *Nat. Clim. Change* 3, 497–501. doi: 10.1038/nclimate1832
- Lobell, D. B., Roberts, M. J., Schlenker, W., Braun, N., Little, B. B., Rejesus, R. M., et al. (2014). Greater sensitivity to drought accompanies maize yield increase in the US Midwest. *Science* 344, 516–519. doi: 10.1126/science.1251423
- Lobell, D. B., Schlenker, W., and Costa-Roberts, J. (2011b). Climate trends and global crop production since 1980. *Science* 333, 616–620. doi: 10.1126/science.1204531
- Loreau, M., Naeem, S., Inchausti, P., Bengtsson, J., Grime, J. P., Hector, A., et al. (2001). Biodiversity and ecosystem functioning: current knowledge and future challenges. *Science* 294, 804–808. doi: 10.1126/science.1064088
- Marshall, E., and Brown, V. (2003). The role of weeds in supporting biological diversity within crop fields. *Weed Res.* 44, 77–89. doi: 10.1046/j.1365-3180.2003.00326.x
- Miedema, P. (1982). The effects of low temperature on Zea mays. *Adv. Agron.* 35, 93–128. doi: 10.1016/S0065-2113(08)60322-3
- Mittelbach, G., Steiner, C., and Scheiner, S. (2001). What is the observed relationship between species richness and productivity? *Ecology* 82, 2381–2396. doi: 10.1890/0012-9658(2001)082[2381:WITORB]2.0.CO;2
- Morvillo, C. M., de la Fuente, E. B., Gil, A., Martinez-Ghersa, M. A., and Gonzalez-Andujar, J. L. (2011). Competitive and allelopathic interference between soybean crop and annual wormwood (*Artemisia annua* L.) under field conditions. *Eur. J. Agron.* 34, 211–221. doi: 10.1016/j.eja.2011.01.004
- Mourtzinis, S., Specht, J. E., Lindsey, L. E., Wiebold, W. J., Ross, J., Nafziger, E. D., et al. (2015). Climate-induced reduction in US-wide soybean yields underpinned by region- and in-season-specific responses. *Nat. Plants* 1:14026. doi: 10.1038/nplants.2014.26
- Muchow, R. C. (1990). Effect of high temperature on grain-growth in field-grown maize. *Field Crop Res.* 23, 145–158. doi: 10.1016/0378-4290(90)90109-0
- Muchow, R. C., Sinclair, T. R., and Bennett, J. M. (1990). Temperature and solar radiation effects on potential maize yield across locations. *Agron. J.* 82, 338–343.
- Naeem, S. (2008). Species redundancy and ecosystem reliability. *Conserv. Biol.* 12, 39–45. doi: 10.1111/j.1523-1739.1998.96379.x
- Oksanen, J. (2013). *Vegan: Ecological Diversity*. Available online at: <https://labscn-unalmed.github.io/ecologia-numerica/docs/diversity-vegan.pdf>
- Ort, D. R., and Long, S. P. (2014). Limits on yields in the corn belt. *Science* 344, 484–485. doi: 10.1126/science.1253884
- Petit, S., and Boursault, A. (2010). Weeds in agricultural landscapes. A review. *Agron. Sustain. Dev.* 31, 309–317. doi: 10.1051/agro/2010020
- R Development Core Team (2011). *R: A Language and Environment for Statistical Computing*. Vienna: R Foundation for Statistical Computing.
- Ricker, W. E. (1954). Stock and recruitment. *J. Fish. Res. Board Can.* 11, 559–623. doi: 10.1139/f54-039
- Robertson, G. P., Gross, K. L., Hamilton, S. K., Landis, D. A., Schmidt, T. M., Snapp, S. S., et al. (2014). Farming for ecosystem services: an ecological approach to production agriculture. *Bioscience* 64, 404–415. doi: 10.1093/biosci/biu037
- Robertson, G. P., and Hamilton, S. K. (2015). "Long-term ecological research at the Kellogg Biological Station LTER site" in *The Ecology of Agricultural Landscapes: Long-Term Research on the Path to Sustainability*, eds S. K. Hamilton, J. E. Doll, and G. P. Robertson. (New York, NY: Oxford University Press), 1–32.
- Royama, T. (1992). *Analytical Population Dynamics*. London; New York, NY: Chapman & Hall: Springer.
- Schlenker, W., and Roberts, M. J. (2009). Nonlinear temperature effects indicate severe damages to US crop yields under climate change. *PNAS* 106, 15594–15598. doi: 10.1073/pnas.0906865106

- Smith, R. G., Gross, K. L., and Robertson, G. P. (2008). Effects of crop diversity on agroecosystem function: crop yield response. *Ecosystems* 11, 355–366. doi: 10.1007/s10021-008-9124-5
- Smith, R. G., Ryan, M. R., and Menalled, F. D. (2011). "Direct and indirect impacts 1024 of weed management practices on soil quality," in *Soil Management: Building a Stable Base for Agriculture*, eds J. L. Hatfield and T. J. Sauer (Madison, WI: SSSA), 275–286.
- Swift, M. J., Izac, A.-M. N., and van Noordwijk, M. (2004). Biodiversity and ecosystem services in agricultural landscapes—are we asking the right questions? *Agric. Ecosyst. Environ.* 104, 113–134. doi: 10.1016/j.agee.2004.01.013
- Symstad, A. J., Chapin, F. S., Wall, D. H., Gross, K. L., Huenneke, L. F., Mittelbach, G. G., et al. (2003). Long-term and large-scale perspectives on the relationship between biodiversity and ecosystem functioning. *Bioscience* 53, 89. doi: 10.1641/0006-3568(2003)053[0089:LTALSP]2.0.CO;2
- Tilman, D. (1999). The ecological consequences of changes in biodiversity: a search for general principles. *Ecology* 80, 1455–1474. doi: 10.2307/176540
- Tilman, D., Cassman, K. G., Matson, P. A., Naylor, R., and Polasky, S. (2002). Agricultural sustainability and intensive production practices. *Nature* 418, 671–677. doi: 10.1038/nature01014
- Tilman, D., Reich, P. B., Knops, J., Wedin, D., Mielke, T., and Lehman, C. (2001). Diversity and productivity in a long-term grassland experiment. *Science* 294, 843–845. doi: 10.1126/science.1060391
- Tilman, D., Wedin, D., and Knops, J. (1996). Productivity and sustainability influenced by biodiversity in grassland ecosystems. *Nature* 379, 718–720. doi: 10.1038/379718a0
- Vandermeer, J., van Noordwijk, M., Anderson, J., Ong, C., and Perfecto, I. (1998). Global change and multi-species agroecosystems: concepts and issues. *Agric. Ecosyst. Environ.* 67, 1–22. doi: 10.1016/S0167-8809(97)00150-3
- Vilà, M., Inchausti, P., and Vayreda, J. (2005). "Confounding factors in the observational productivity-diversity relationship in forests," in *Forest Diversity and Function*, eds M. Scherer-Lorenzen, C. Körner, and E.-D. Schulze (Berlin; Heidelberg: Springer-Verlag), 65–86.

Conflict of Interest Statement: The authors declare that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.

Copyright © 2017 Ferrero, Lima, Davis and Gonzalez-Andujar. This is an open-access article distributed under the terms of the Creative Commons Attribution License (CC BY). The use, distribution or reproduction in other forums is permitted, provided the original author(s) or licensor are credited and that the original publication in this journal is cited, in accordance with accepted academic practice. No use, distribution or reproduction is permitted which does not comply with these terms.

Capítulo 5

5. Discusión general

Para satisfacer la creciente demanda mundial de alimentos de manera sostenible debemos **aumentar el rendimiento de los cultivos y su estabilidad** haciendo frente al **impacto del cambio climático** ([Grassini et al. 2013](#)). Hasta ahora los modelos estadísticos utilizados consideraban que el rendimiento del cultivo seguía el comportamiento del clima en el cual se encuentra, pero esto no concordaba con los nuevos hallazgos de **estancamiento** del rendimiento ni con la biología del cultivo (e.g. **limitaciones biofísicas**; [Brisson et al. 2010](#), [Ray et al. 2012](#), [Grassini et al. 2013](#)). Los resultados sobre la magnitud, la tasa y el patrón de los impactos del cambio climático en la productividad agrícola diferían y eran difíciles de comparar ([Lobell & Burke 2008](#), [Porter et al. 2014](#)). Además, dichos modelos solo explicaban alrededor del 30% de la variabilidad encontrada en el rendimiento de los cultivos ([Lobell & Field 2007](#)), lo cual indicaba que **otros factores tenían que estar implicados**.

En esta tesis hemos propuesto una aproximación novedosa basada en la **teoría de sistemas dinámicos** para evaluar los distintos tipos de **factores (internos y externos)** que pueden determinar la dinámica del rendimiento del cultivo bajo el efecto del cambio climático. Para ello, incluimos explícitamente en los modelos estadísticos: 1) los **factores internos** (e.g. limitaciones biofísicas) que determinan la **estructura** y el comportamiento

dinámico del rendimiento de los cultivos, y 2) los **factores externos** (e.g. cambio climático, CO₂, malezas y riego) que perturban o impactan sobre el rendimiento del cultivo con diferentes tipos de respuestas (aditivas y no aditivas).

Nuestros resultados permitieron lograr una comprensión más profunda y realista sobre los procesos agroecológicos que determinan la dinámica del rendimiento de los cultivos para hacer frente a los impactos del cambio climático. Hallamos **características comunes** entre las dinámicas de rendimiento de los cultivos debido a limitaciones de crecimiento, respuestas complejas de los cultivos a los cambios climáticos y puntos críticos que son cruciales para la adaptación y la mitigación del cultivo de manera sostenible. A partir de esta comprensión hemos propuesto medidas de manejo eficientes para aumentar el rendimiento de los cultivos y su estabilidad. Nuestra aproximación permitirá generar predicciones más precisas y proponer medidas de manejo más eficientes ([Lobell & Burke 2008](#)).

A continuación presentamos una discusión general de los principales resultados de esta tesis.

La tasa de crecimiento del rendimiento en general disminuye para sistemas de alto rendimiento

Detectamos y modelamos una **disminución** en la tasa de crecimiento del rendimiento del cultivo (RGR) cuando nos acercamos a su **capacidad máxima** (donde $RGR=0$). Nuestros resultados coinciden con los últimos hallazgos que indican que en **los países con mayor producción existe una desaceleración** generalizada en la tasa relativa de aumento de los rendimientos de los cultivos ([Grassini et al 2013](#)). Por lo tanto, los países donde podremos obtener los mayores incrementos en la producción futura de granos son aquellos donde las brechas de rendimiento actuales son grandes ([Grassini et al 2013](#)). La mejor manera de asegurar la producción

sería **difundir aún más la tecnología de manejo a los cultivos de bajo rendimiento** (los cuales tienen mayor potencial de crecimiento) o **acelerar el desarrollo y difusión de nuevas tecnologías** que liberen al cultivo de estas limitaciones ([Tester & Langridge 2010](#), [Foley et al. 2011](#)).

Los resultados respaldan firmemente la idea de que las estimaciones de la producción futura de cereales deben derivarse de proyecciones de rendimiento basadas en la existencia de un **límite superior biofísico para el rendimiento** del grano acorde con la biología del cultivo ([Ray et al. 2012](#), [Lin & Huyber 2012](#), [Grassini et al 2013](#)) pero aquí, además, propusimos una herramienta útil y sencilla para su estimación. Utilizamos, por primera vez, el **modelo de crecimiento logístico** para representar la dinámica del rendimiento del cultivo ante el cambio climático. Este modelo tiene una **interpretación biológica simple e intuitiva** en términos de la capacidad de aumento del rendimiento, y **es fácil de implementar** ([Paine et al. 2012](#)). Se trata de una función intrínsecamente **no lineal**, ampliamente empleada en varios tipos de sistemas dinámicos (e.g. -para animales- [Berryman 1999](#) y -plantas- [Paine et al. 2012](#)).

Nuestros modelos presentan **importantes ventajas** respecto a las aproximaciones anteriores. Hasta ahora, para evaluar la dinámica del rendimiento en los cultivos, se han utilizado **modelos lineales sin restricciones** ([Lobell et al. 2011](#)), modelos **polinómicos** ([Schlenker & Roberts 2009](#)) o con un **punto de corte discontinuo** (con umbrales para representar el estancamiento del rendimiento; [Grassini et al 2013](#)). Los primeros no concuerdan con las propiedades biológicas del cultivo ya que asumen un crecimiento constante e **ilimitado**, y los dos últimos fallan en explicar y modelar la **respuesta funcional** del cultivo mediante **mecanismos biológicos reales**. Además, el modelo logístico que hemos propuesto presenta mejores propiedades de interpolación y extrapolación respecto a los modelos polinómicos o de umbral empleados actualmente ([Paine et al. 2012](#)). Con estos modelos podríamos detectar si el **estancamiento** del rendimiento del cultivo tiene una **causa biológica** (límites biofísicos internos

del cultivo) o no, ya que algunos autores proponen también causas socioeconómicas o climáticas ([Iizumi et al. 2017](#)). Podríamos incluso predecir de manera explícita el **momento** en el que es probable que el rendimiento del cultivo **se estanque** y así proponer medidas de manejo eficaces para evitarlo.

La herramienta que hemos propuesto nos ha permitido también **estandarizar**, es decir, explicar y comparar mediante una misma función el comportamiento de cultivos de alto y bajo rendimiento (como se ha realizado también para modelos de crecimiento en plantas, ver [Paine et al. 2012](#)). Como hemos mencionado, la RGR a menudo disminuye a medida que el rendimiento del cultivo aumenta, lo que **dificulta la comparación** de cultivos con distinto nivel de rendimiento. Los resultados contradictorios o confusos de la bibliografía anterior (e.g. [Porter et al. 2014](#)) podrían reflejar en realidad diferencias en la respuesta entre cultivos con distintos niveles promedio de rendimiento.

En todos los cultivos y en la mayoría de las regiones el rendimiento del cultivo estuvo regulado

En distintos tipos de cultivos (cereales y oleaginosas, cultivos de verano e invierno, C3 y C4, etc.), y en la mayoría de las regiones, detectamos una **estructura interna similar**. Identificamos procesos de **regulación o limitación** del sistema mediante un mecanismo de retroalimentación negativa de primer orden con un punto de equilibrio dinámico (donde $RGR=0$). Estos mecanismos de **estabilización** suavizaron las fluctuaciones del rendimiento del cultivo hasta cierto punto (i.e. dentro de la cuenta de atracción del punto de equilibrio dinámico; [Royama 1992](#)). Es decir, observamos que el rendimiento del cultivo se mantuvo dentro de determinados valores límites o cerca de ellos y realizó fluctuaciones rápidas año a año, lo cual concuerda con los resultados de estudios previos ([Lobell et al. 2011](#)). Estos resultados nos permitieron evaluar la capacidad de

respuesta y recuperación del cultivo ante modificaciones de su ambiente, mejorando nuestra comprensión sobre la dinámica de su rendimiento, como recomendaron Lobell & Burke ([2008](#)). Además, nos indican que los sistemas de cultivo podrían mostrar fluctuaciones en su rendimiento por motivos puramente intrínsecos (incluso en ambientes estables).

La **regulación** de los sistemas biológicos es **muy extendida pero no universal**, puede que no siempre opere ni en todo momento ([Royama 1992](#)). Por lo tanto, sería interesante **comparar más cultivos** (comparar, por ejemplo, distintos grupos funcionales de cultivos) **y en un mayor número de regiones** para evaluar **bajo qué condiciones** podemos encontrar regulación en los sistemas de cultivo. Esto nos permitiría proponer nuevas medidas de manejo para estabilizar y aumentar el rendimiento de los cultivos.

Las perturbaciones externas (cambio climático, CO2 y malezas) explicaron más de un tercio de la variabilidad del rendimiento del cultivo

Nuestros resultados han confirmado la importancia de la regulación interna sobre la dinámica de los cultivos, pero también las **perturbaciones externas juegan un papel importante** a la hora de explicar dicha dinámica. Los modelos estadísticos utilizados hasta ahora afirman que alrededor de un 30% de la variabilidad del rendimiento se debe a factores climáticos (a nivel global [Ray et al. 2015](#) o regional [Verón et al. 2015](#)). Los modelos presentados en esta tesis **explican entre un 30-83% de dicha variabilidad**.

Detectamos cuáles han sido los **cultivos de cereales y las regiones más afectadas** por el cambio climático, el aumento de CO2, las diferencias en el sistema de riego y la diversidad de malezas, en España, Sudamérica y Michigan-EEUU. Principalmente detectamos efectos negativos de las **temperaturas máximas y mínimas**, en línea con algunas investigaciones

recientes ([Lobell et al. 2011a](#), [Lobell & Gourdj 2012](#)), pero también encontramos regiones afectadas por las altas precipitaciones y por niveles altos del CO₂ atmosférico. Hasta ahora pocos estudios han comparado de manera explícita los impactos del cambio climático para diferentes regiones y/o cultivos ([Porter et al. 2014](#)). A diferencia de la literatura existente que utiliza datos a nivel nacional ([Lobell & Fiel 2007](#), Lobell et al. [2011a](#), [2011b](#), Ray et al. [2012](#), [2015](#), [Grassini et al. 2013](#)), aquí hemos utilizado datos a una escala menor (subnacional). Esta aproximación nos permitió identificar una **gran heterogeneidad espacial** en los principales factores externos que impactan sobre el rendimiento de los cultivos y proponer **medidas de manejo** específicas a cada contexto. En este sentido, la utilización de menores escalas de análisis parecen indicar una **mayor capacidad de detección** de los efectos del cambio climático. Como indica [Porwollik et al. \(2017\)](#), en la agregación a escala de país, para países con grandes áreas cosechadas, las incertidumbres espaciales pueden cancelarse y disminuir la capacidad de detectar efectos significativos. Las herramientas que hemos propuesto podrán ser además empleadas en **otras regiones claves** para asegurar las necesidades alimentarias en un futuro próximo.

Las respuestas del cultivo ante las perturbaciones externas fueron principalmente no lineales

Hemos identificado **cómo los factores externos** afectan al rendimiento del cultivo. Un aspecto novedoso que se desprende de nuestros resultados es el hecho de que los **efectos climáticos no aditivos** (o no lineales; i.e. el efecto de la interacción entre el clima y el rendimiento del cultivo) **son más comunes que los aditivos** (i.e. el efecto del clima es independiente del rendimiento del cultivo). Los modelos publicados hasta ahora, incluso los que modelan respuestas no lineales del rendimiento de los cultivos ante el impacto del cambio climático (e.g. [Schlenker & Roberts 2009](#)), no diferencian la respuesta entre un sistema de cultivo de alto o bajo rendimiento. Sin embargo, nuestros resultados indican que los impactos del

cambio climático son mayores cuando el cultivo se encuentra cercano a su **capacidad máxima de rendimiento**, cuando los cultivos demandan más nutrientes pero la disponibilidad de recursos disminuye o permanece constante. Por ejemplo, un cultivo usualmente no responde de la misma manera a la disponibilidad de agua en sistemas de alto rendimiento (gran biomasa) o cuando tiene bajos niveles de rendimiento (pequeña biomasa; ver por ejemplo [Doorenbos y Kassam 1979](#)). Generalmente, cuando el cultivo tiene un rendimiento mayor, también tiene una mayor demanda de agua y, por lo tanto, si no consideramos esta respuesta diferencial estaríamos sobreestimando la respuesta del cultivo al cambio climático, al menos para los sistemas de alto rendimiento.

Nuestros resultados sugieren, por tanto, que **los cultivos de alto rendimiento son los más vulnerables al cambio climático**, para estos cultivos un pequeño cambio en el clima puede disminuir considerablemente su rendimiento. Este hallazgo podría explicar por qué los cultivos con alto rendimiento suelen presentar una mayor inestabilidad (Ben-Ari & Makowski [2014](#), [2016](#)). Los mecanismos de limitación interna del cultivo, que son mayores para sistemas de alto rendimiento, influyen en su capacidad de recuperación ante el impacto del cambio climático. Se trata de un resultado **crucial**, ya que ignorar la **respuesta diferencial** de cultivos de bajo y alto rendimiento conduciría a **predicciones imprecisas** sobre el impacto del cambio climático sobre los cultivos. Además, debido a que la mayoría de los cultivos son básicamente **sistemas definidos en altos niveles de rendimiento**, es esencial modelar y predecir los problemas que generan los efectos climáticos no aditivos. Esta aproximación nos permitiría evitar posibles **conclusiones contradictorias** sobre el efecto del cambio climático para un mismo cultivo ([Porter et al 2014](#)). La confianza de nuestras **predicciones** y la **comprensión mecanicista** de la dinámica del rendimiento de los cultivos están influenciadas por la consideración de enfoques aditivos o no aditivos (ver, por ejemplo, [Schlenker & Roberts 2009](#)).

La consecuencia de los efectos aditivos y no aditivos del cambio climático sobre el rendimiento de los principales cultivos de cereales son distintas. Los factores externos perturban la estructura interna del cultivo, cambiando la forma de la función RGR, su estabilidad y/o su valor de equilibrio ([Berryman 1999](#)). Los efectos aditivos implican cambios en la **capacidad máxima de crecimiento** del rendimiento del cultivo y en la **estabilidad** de sus fluctuaciones, mientras que los efectos no aditivos solo incluyen cambios en su **rendimiento potencial** ([Royama 1992](#)). Cabe mencionar que según la teoría ecológica solo un tipo de retroalimentación es capaz de **dominar** la dinámica del sistema cerca del equilibrio (**ley del mínimo** de [Liebig 1840](#)). Sin embargo, esta **retroalimentación puede cambiar en el tiempo** debido a factores internos o externos. Por ejemplo, debido a la presión del cambio climático el sistema de cultivo podría cambiar hacia una estructura más compleja con múltiples estados estables alternativos (dinámicas meta-estables, ver [Berryman 1999](#)). Predecir la existencia de este tipo de cambios puede ser crucial para la seguridad alimentaria a largo plazo. En ecología existen varios ejemplos de este tipo, debido a las perturbaciones de El Niño ([Lima et al. 1999](#)) o a cambios estacionales ([Hansen et al. 1999](#)).

El riego y la diversidad de malezas como medidas de adaptación y mitigación al cambio climático

La adaptación y mitigación del impacto del cambio climático sobre la agricultura pasa por la mejora de la eficiencia en el uso de los recursos utilizados en la agricultura (e.g. agua, suelo, diversidad del sistema, etc.; [Porter et al. 2014](#)).

Una de las opciones existentes para adaptar los cultivos es un manejo eficiente del agua de riego ([Siebert & Döll 2010](#), [Piao et al. 2010](#), [Porter et al. 2014](#)). En el estudio realizado para el maíz en España, hemos presentado

una **nueva técnica para estimar el rendimiento potencial del cultivo** en una región y su **brecha de rendimiento** debido al estrés hídrico. Identificamos las zonas donde el **riego** disminuyó gran parte de estas **brechas de rendimiento** y zonas donde fue capaz de **aminorar los impactos del cambio climático**. La **efectividad del riego** se vió afectada en gran medida por el aumento de la **temperatura** en España en la últimas décadas, como ha ocurrido también con el maíz en China ([Sun & Van Kooten 2013](#)). La aparente paradoja de no detectar efectos significativos de la precipitación sobre el rendimiento de los cultivos de secano, puede deberse a que el aumento de la temperatura aumenta el estrés hídrico del cultivo (i.e. determina la oferta y/o demanda de agua para el cultivo; [Lobell et al. 2013](#)). Pero además de estos hallazgos, nuestros modelos nos han permitido detectar sus **consecuencias dinámicas** sobre el maíz: el aumento de la temperatura disminuye su rendimiento promedio pero sin afectar demasiado la estabilidad del cultivo (efecto no aditivo). Nuevamente, fueron los sistemas de cultivo de alto rendimiento en el maíz los más vulnerables al calentamiento. Obtuvimos un **mapa de vulnerabilidades y potencialidades** a partir del cual desarrollar las estrategias de adaptación y mitigación del cambio climático en España.

Diversos autores han sugerido que un incremento de la diversidad podría reducir la competencia con el cultivo como consecuencia de que un incremento de la diversidad de la flora arvense supondría una reducción de la densidad de la/s maleza/s dominante/s (fuertemente competitivas con el cultivo) a través de un efecto de competencia interespecífica dentro de la comunidad arvense y, por consiguiente, una reducción de la presión competitiva sobre el cultivo ([Cléments et al. 1994](#), [Hooper et al. 2005](#), [Pollnac et al. 2009](#)). Siguiendo esta idea, en segundo lugar, evaluamos la capacidad de la **diversidad de malezas** del sistema agrícola para **beneficiar la producción del cultivo**. A partir del experimento a largo plazo con el maíz y la soja en Michigan-EEUU, hemos visto que es posible **gestionar la biodiversidad de un agro-ecosistema** de tal manera de mantener o reforzar sus funciones y servicios **para optimizar la producción agrícola y contribuir**

a su **resistencia ante los disturbios ambientales**. El rendimiento de la soja se vio favorecido por una comunidad de malezas más **equitativa** (efectos aditivos). En el maíz detectamos que es durante **los años de alto rendimiento y condiciones climáticas extremas** donde se debe **disminuir la dominancia de algunas malezas** para mejorar los rendimientos de los cultivos (efectos no aditivos). Modelamos **efectos simultáneos y compuestos** en el rendimiento de los cultivos que podrían **no ser detectados (o podrían confundirse)** si se analizan los efectos de disturbio por separado. Finalmente, hemos **desmitificado** la percepción generalizada de que las malezas solo son perjudiciales para los cultivos. Se pueden equilibrar las necesidades del control de malezas con los requisitos de biodiversidad y métodos de producción más sostenibles, como han indicado otros autores previamente ([Marshall et al. 2003](#)).

Tanto en la evaluación del riego como en la diversidad de la comunidad de malezas, hemos observado que **ignorar las respuestas no aditivas** podría conducir a **predicciones sobre-estimadas** sobre las herramientas de adaptación y mitigación al cambio climático, asumiendo que son **igualmente efectivas** a niveles de rendimiento bajos y alto cuando en realidad no lo son.

Otros aspectos a desarrollar en el futuro

Nuestra aproximación sistémica (**unificadora**) mediante la RGR nos permite **conectar con otro tipo de estudios a otra escala de resolución** (e.g. estudios alométricos, de historia de vida o evolutivos; [Paine et al. 2012](#)). Esto nos podría ayudar a determinar experimentalmente **qué tipos de procesos biofísicos** producen la estructura interna y regulación observada. Si conociéramos los procesos internos al cultivo que causan regulación/estabilidad o, por el contrario comportamientos cíclicos o de mayor inestabilidad (e.g. que modifican el largo, amplitud, sincronía del

ciclo, etc.; ver [Watt, Stork & Hunter, 1997](#)) podríamos modificarlos para disminuir sus efectos negativos sobre la seguridad alimentaria.

Esta tesis abre también nuevas posibilidades para el estudio de **otros recursos (e.g. insumos agrícolas)**, otros aspectos de la **biodiversidad del sistema agrícola (e.g. diversidad de insectos)** y para la creación de **modelos predictivos**. En relación a esto último, mediante los modelos propuestos en esta tesis se podrían **estimar, a corto y medio plazo, las proyecciones del rendimiento del cultivo para distintos escenarios climático y de manejo hídrico**. En particular, podemos lograr un **gran progreso en nuestras predicciones** sobre el impacto del cambio climático a medio plazo si evaluamos explícitamente la **estabilidad** del sistema además de proyectar las **tendencias medias** como se han analizado hasta ahora ([Porter et al 2014](#)).

La **escasez de datos estatales diarios y/o regionales** no nos han permitido considerar la influencia del **momento** en que ocurren los eventos climáticos, que son importantes para el desarrollo y crecimiento de los cultivos ([Slingo et al. 2005](#)). Si bien a escalas amplias como las de nuestros estudios, la importancia del momento específico a menudo disminuye ([Schlenker & Roberts, 2009](#); [Lobell & Burke, 2010](#)), los **efectos puntuales en el tiempo** pueden ser particularmente importantes cuando se evalúa la producción de cultivos a nivel más local ([Welch et al., 2010](#) y [Lobell et al., 2011b](#)). Asimismo, sería interesante incluir **estimaciones regionales del nivel de CO2 atmosférico** en nuestros modelos pero hasta ahora solo contamos con **largas series históricas** para valores a nivel nacional. Como mencionamos en la introducción, se trata de un tema ampliamente debatido y en el que aún no existe un consenso sobre su efecto sobre los cultivos e interacción con las demás variables climáticas.

Por último, sería interesante estudiar el efecto de la **correlación espacial de los factores externos** (e.g. clima, CO2, malezas, etc.) en la **sincronía regional de los estancamientos de los cultivos** (el efecto Morán,

ver [Royama 1992](#)). El efecto Moran predice variaciones sincrónicas en los sistemas dinámicos cuando estos presentan estructuras de regulación similares y experimentan variaciones climáticas correlacionadas. Se espera que para cultivos con similares estructuras de regulación y ambiente, las dinámicas se acoplen en el tiempo. La sincronía implica riesgos y oportunidades para el control de la producción de alimentos. Por ejemplo, las medidas de mitigación y adaptación ante el impacto del cambio climático podrían ser subestimadas si debido al efecto Moran se producen eventos recurrentes de estancamiento y colapso en varios sitios cercanos y por varios tipos de cultivos. Analizar la sincronía para una amplia gama de cultivos y regiones permitiría evaluar qué tan frecuente es este fenómeno y bajo qué condiciones ha de esperarse que ocurra.

En resumen, en esta tesis hemos desarrollado **nuevas herramientas matemáticas** inspiradas en la teoría de dinámica de sistemas y en ecología poblacional que nos permitieron **comprender la dinámica del rendimiento** de los cultivos ante procesos de **regulación interna** y de **perturbación externa (e.g. cambio climático)**. Nuestros resultados indican que las **reglas** que gobiernan la dinámica del rendimiento de los cultivos son relativamente **simples**, el variado comportamiento que observamos en la naturaleza es una consecuencia de la **estructura del sistema** y no de la complejidad de las reglas subyacentes. Los modelos que desarrollamos son **generales** y se pueden aplicar a una **gran variedad de cultivos**.

Hemos detectado temas claves que determinan la dinámica del rendimiento del cultivo, por ejemplo: su regulación, cómo y cuándo ocurre, la existencia de respuestas no lineales ante perturbaciones climáticas debido a que el cultivo no responde de la misma manera en un sistema de alto o bajo rendimiento, la importancia de la diversidad del agroecosistema como otro factor externo a considerar en los estudios de rendimiento, la disminución de las brechas de rendimiento de los cultivos mediante el manejo hídrico, los análisis a escala subnacional para ofrecer medidas de

manejo más específicas, etc.. Gracias a esta comprensión hemos podido proponer distintas medidas de **adaptación y mitigación** a medio plazo en situaciones y regiones estratégicas para la seguridad alimentaria. Esperamos que esta contribución **desmitifique los conceptos de regulación y no linealidad en los sistemas agrícolas**, que aporte una **perspectiva ecológica más realista** a los modelos estadísticos utilizados actualmente en el análisis del impacto del cambio climático sobre los cultivos y persuada a más científicos a utilizar estas técnicas.

Capítulo 6

6. Conclusiones

El análisis de las tasas de crecimiento del rendimiento de los principales cultivos de cereales es un área creciente de investigación que aborda el gran desafío de satisfacer la demanda futura de alimentos y adaptarnos al cambio climático. En esta tesis utilizamos un nuevo enfoque conceptual basado en la teoría de la dinámica poblacional para aportar una **comprensión más profunda** sobre los procesos agroecológicos que determinan la dinámica del rendimiento de los cultivos. Detectamos y modelamos la **desaceleración** de esta tasa para sistemas de cultivo de alto rendimiento y evaluamos los **mecanismos internos** que generan su **regulación**. Analizamos también los distintos tipos de **perturbación externa** que sufre el cultivo (con efectos aditivos y no aditivos), por ejemplo debidos al cambio climático y al nivel atmosférico de CO₂, entre otros. Discutimos las consecuencias dinámicas de ambos tipos de factores (internos y externos) sobre el rendimiento del cultivo (estabilidad, rendimiento máximo, etc.). Identificamos aquellos cultivos y regiones que han sido más **vulnerables** ante las recientes tendencias del **cambio climático** en los agroecosistemas de Sudamérica y España, dos regiones claves para la seguridad ambiental y especialmente vulnerables.

Por último, evaluamos distintas **medidas de adaptación y mitigación** de los impactos del cambio climático para mejorar la producción de los cultivos en el futuro próximo. Analizamos la **efectividad del riego** para disminuir la brecha del rendimiento de los cultivos y, mediante el análisis de experimentos a largo plazo, determinamos bajo qué circunstancias la

diversidad de la comunidad de malezas puede no afectar negativamente a los cultivos de maíz y soja y cómo interacciona con el clima.

Las proyecciones anteriores de seguridad alimentaria a menudo son **más optimistas** de lo que indican las tendencias históricas de rendimiento, ya que suponen tasas constantes de ganancia de rendimiento. Aquí proporcionamos una nueva aproximación que permite caracterizar los patrones de rendimiento y explicar los estancamientos observados en las series de rendimiento históricas mediante una disminución en la tasa relativa de ganancia cuando nos acercamos a la capacidad máxima de rendimiento. Nuestros resultados indican que las predicciones de la producción de cereales **deberían reflejar** la naturaleza no lineal del crecimiento del rendimiento del cultivo, la existencia de límites biofísicos en el rendimiento y las posibles respuestas no aditivas del cultivo ante el cambio climático u otros agentes de perturbación externa. De este modo podremos generar predicciones más fiables, planificar y priorizar aquellas estrategias que nos permitan garantizar la seguridad alimentaria y la conservación de los recursos naturales en el futuro.

Referencias

1. Ainsworth, E.A., & Long, S.P. (2005). What have we learned from 15 years of free-air CO₂ enrichment (FACE)? A meta-analytic review of the responses of photosynthesis, canopy properties and plant production to rising CO₂. *New Phytologist*, 165(2), 351-372.
2. Alexander, L.V., Zhang, X., Peterson, T.C., Caesar, J., Gleason, B., Klein Tank, A.M.G., Haylock, M., Collins, D., Trewin, B., Rahimzadeh, F., Tagipour, A., Rupa Kumar, K., Revadekar, J., Griffiths, G., Vincent, L., Stephenson, D.B., Burn, J., Aguilar, E., Brunet, M., Taylor, M., New, M., Zhai, P., Rusticucci, M., Vazquez-Aguirre, J.L. (2006). Global observed changes in daily climate extremes of temperature and precipitation. *Journal of Geophysical Research: Atmospheres*, 111(D5).
3. Altieri, M.A. (1999). The ecological role of biodiversity in agroecosystems. In *Invertebrate Biodiversity as Bioindicators of Sustainable Landscapes*. pp. 19-31.
4. Amthor, J.S. (2001). Effects of atmospheric CO₂ concentration on wheat yield: review of results from experiments using various approaches to control CO₂ concentration. *Field Crops Research*, 73(1), 1-34.
5. Archambault, D.J., (2007). Efficacy of herbicides under elevated temperature and CO₂. In: *Agroecosystems in a Changing Climate*. Newton, P.C.D., A. Carran, G.R. Edwards, and P.A. Niklaus, Eds.. CRC Press, Boston, MA, pp. 262-279.
6. Ben-Ari, T., & Makowski, D. (2016). Analysis of the trade-off between high crop yield and low yield instability at the global scale. *Environmental Research Letters*, 11(10), 104005.
7. Ben-Ari, T., & Makowski, D. (2014). Decomposing global crop yield variability. *Environmental Research Letters*, 9(11), 114011.
8. Berryman, A.A. (1991). Stabilization or regulation: what it all means!. *Oecologia*, 86(1), 140-143.
9. Berryman, A.A. (1999). *Principles of population dynamics and their application*. Stanley Thornes (Publishers). Ltd. Cheltenham.

10. Berryman, A.A., & Kindlmann, P. (2008). *Population systems: a general introduction*. Springer Science & Business Media.
11. Bindoff, N.L., P.A. Stott, K.M. AchutaRao, M.R. Allen, N. Gillett, D. Gutzler, K. Hansingo, G. Hegerl, Y. Hu, S. Jain, I.I. Mokhov, J. Overland, J. Perlwitz, R. Sebbari and X. Zhang, (2013). Detection and Attribution of Climate Change: from Global to Regional. In: *Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. Stocker, T.F., D. Qin, G.-K. Plattner, M. Tignor, S.K. Allen, J. Boschung, A. Nauels, Y. Xia, V. Bex and P.M. Midgley, Eds.. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA.
12. Bolker, B.M. (2008). *Ecological models and data in R*. Princeton University Press.
13. Brisson, N., Gate, P., Gouache, D., Charmet, G., Oury, F.X., & Huard, F. (2010). Why are wheat yields stagnating in Europe? A comprehensive data analysis for France. *Field Crops Research*, 119(1), 201-212.
14. Bunce J.A. (2012) Responses of cotton and wheat photosynthesis and growth to cyclic variation in carbon dioxide concentration. *Photosynthetica*;50 495-400.
15. Calderini, D.F., & Slafer, G.A. (1998). Changes in yield and yield stability in wheat during the 20th century. *Field Crops Research*, 57(3), 335-347.
16. Cassman, K.G. (1999). Ecological intensification of cereal production systems: yield potential, soil quality, and precision agriculture. *Proceedings of the National Academy of Sciences*, 96(11), 5952-5959.
17. Castellanos-Frías, E., García de León, D., Pujadas-Salva, A., Dorado, J., & Gonzalez-Andujar, J.L. (2014). Potential distribution of *Avena sterilis* L. in Europe under climate change. *Annals of applied biology*, 165(1), 53-61.
18. Challinor, A.J., & Wheeler, T.R. (2008). Use of a crop model ensemble to quantify CO₂ stimulation of water-stressed and well-watered crops. *Agricultural and Forest Meteorology*, 148(6), 1062-1077.
19. Challinor, A.J., Simelton, E.S., Fraser, E.G. & D. Hemming (2010). Increased crop failure due to climate change: assessing adaptation options using models and socio-economic data for wheat in China. *Environmental Research Letters*, 5(3), 034012.
20. Challinor, A.J., Watson, J., Lobell, D.B., Howden, S.M., Smith, D.R., & Chhetri, N. (2014). A meta-analysis of crop yield under climate change and adaptation. *Nature Climate Change*, 4(4), 287-291.
21. Clément, D.R., Weise, S.F., & Swanton, C.J. (1994). Integrated weed management and weed species diversity. *Phytoprotection*, 75(1), 1-18.
22. Crafts-Brandner, S.J. & Salvucci, M.E. (2002) Sensitivity of photosynthesis in a C₄ plant, maize, to heat stress. *Plant Physiol* 129: 1773-1780
23. Craufurd, P.Q., & Wheeler, T.R. (2009). Climate change and the flowering time of annual crops. *Journal of Experimental Botany*, 60(9), 2529-2539.
24. DaMatta, F.M., Grandis, A, Arenque, B.C., Buckeridge, M.S. (2010). Impacts of climate changes on crop physiology and food quality. *Food Research International* 43, 1814-1823.
25. Doorenbos, J., & Kassam, A.H. (1979). Yield response to water. *Irrigation and drainage paper*, 33, 257.
26. Duvick, D.N., & Cassman, K.G. (1999). Post-green revolution trends in yield potential of temperate maize in the North-Central United States. *Crop Science*, 39(6), 1622-1630.
27. Dyson, T. (1999). Prospects for feeding the world. *BMJ: British Medical Journal*, 319(7215), 988-991.
28. Easterling, D.R., Horton, B., Jones, P.D., Peterson, T.C., Karl, T.R., Parker, D.E., Salinger, M.J., Razuvayev, V., Plummer, N., Jamason, P., Folland, C.K. (1997). Maximum and minimum temperature trends for the globe. *Science*, 277(5324), 364-367.

29. Easterling, D.R., Meehl, G.A., Parmesan, C., Changnon, S.A., Karl, T.R., & Mearns, L. O. (2000a). Climate extremes: observations, modeling, and impacts. *Science*, 289(5487), 2068-2074.
30. Easterling, D.R., Evans, J.L., Groisman, P.Ya, Karl, T.R., Kunkel, K.E., Ambenje, P. (2000b). Observed variability and trends in extreme climate events: a brief review. *Bulletin of the American Meteorological Society*. 81:417-425.
31. Easterling, W.E., P.K. Aggarwal, P. Batima, K.M. Brander, L. Erda, S.M. Howden, A. Kirilenko, J. Morton, J.-F. Soussana, J. Schmidhuber and F.N. Tubiello (2007) Food, bre and forest products. *Climate Change 2007: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*, M.L. Parry, O.F. Canziani, J.P. Palutikof, P.J. van der Linden and C.E. Hanson, Eds., Cambridge University Press, Cambridge, UK, 273-313.
32. Erbs, M., Manderscheid, R., Jansen, G., Seddig, S., Pacholski, A., & Weigel, H.J. (2010). Effects of free-air CO₂ enrichment and nitrogen supply on grain quality parameters and elemental composition of wheat and barley grown in a crop rotation. *Agriculture, ecosystems & environment*, 136(1), 59-68.
33. Erda, L., Wei, X., Hui, J., Yinlong, X., Yue, L., Liping, B., & Liyong, X. (2005). Climate change impacts on crop yield and quality with CO₂ fertilization in China. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 360(1463), 2149-2154.
34. Evans, L.T., & Fischer, R.A. (1999). Yield potential: its definition, measurement, and significance. *Crop science*, 39(6), 1544-1551.
35. Evenson, R.E. (1999). Intellectual property rights, access to plant germplasm, and crop production scenarios in 2020. *Crop Science*, 39(6), 1630-1635.
36. FAO, W.F.P. (2012). IFAD. 2012. *The state of food insecurity in the world*, 1-63.
37. Finger, R. (2010) Evidence of slowing yield growth-the example of Swiss cereal yields. *Food Policy* 35: 175-182.
38. Foley, J.A., Ramankutty, N., Brauman, K.A., Cassidy, E.S., Gerber, J.S., Johnston, M., Mueller N.D., O'Connell, C., Ray, D.K., West, P.C., Balzer, C., Bennett, E.M., Carpenter, S.R., Hill, J., Monfreda, C., Polasky, S., Rockström, J., Sheehan, J., Siebert, S., Tilman, D., Zaks, D.P.M. (2011). Solutions for a cultivated planet. *Nature*, 478(7369), 337-342.
39. Forrester, Jay W. 1961. *Industrial Dynamics*. Waltham, MA: Pegasus Communications. 464 pp.
40. Gilbert, C.L. & Morgan, C.W. (2010). Food price volatility. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 365 3023-34
41. Global Carbon Project (2011) Carbon budget and trends 2010. <http://www.globalcarbonproject.org/carbonbudget> [Acceso 1 enero 2018]
42. Godfray, H.C.J., Beddington, J.R., Crute, I.R., Haddad, L., Lawrence, D., Muir, J.F., Pretty, J., Robinson, S., Thomas, S.M., Toulmin, C. (2010). Food security: the challenge of feeding 9 billion people. *Science*, 327(5967), 812-818.
43. Grassini, P., Eskridge, K.M., & Cassman, K.G. (2013). Distinguishing between yield advances and yield plateaus in historical crop production trends. *Nature communications*, 4, 2918.
44. Gregory, P.J., & Ingram, J.S.I. (2000). Global change and food and forest production: future scientific challenges. *Agriculture, ecosystems & environment*, 82(1), 3-14.
45. Hafner, S. (2003). Trends in maize, rice, and wheat yields for 188 nations over the past 40 years: a prevalence of linear growth. *Agriculture, ecosystems & environment*, 97(1), 275-283.
46. Hansen, T.F., Stenseth, N.C., & Henttonen, H. (1999). Multiannual vole cycles and population regulation during long winters: an analysis of seasonal density dependence. *The American Naturalist*, 154(2), 129-139.

47. Hawkins, E., T.M. Osborne, C.K. Hoa, and A.C. Challinor (2012). Calibration and bias correction of climate projections for crop modelling: an idealised case study over Europe. *Agricultural and Forest Meteorology*, 170, 19-31.
48. Hawkins, E., Fricker, T.E., Challinor, A.J., Ferro, C. A., Ho, C.K., & Osborne, T.M. (2013). Increasing influence of heat stress on French maize yields from the 1960s to the 2030s. *Global change biology*, 19(3), 937-947.
49. Hatfield, J.L., Boote, K.J., Kimball, B.A., Ziska, L.H., Izaurralde, R.C., Ort, D., Thomson, A.M., Wolfe, D. (2011) Climate impacts on agriculture: implications for crop production. *Agronomy Journal* 103: 351-370
50. Hasegawa, T., Sakai, H., Tokida, T., Hasegawa, T., Sakai, H., Tokida, T., Nakamura, H., Zhu, C., Usui, Y., Yoshimoto, M., Fukuoka, M., Wakatsuki, H., Katayanagi, N., Matsunami, T., Kaneta, Y., Sato, T., Takakai, F., Sameshima, R., Okada, M., Mae, T., Makino, A. (2013). Rice cultivar responses to elevated CO₂ at two free-air CO₂ enrichment (FACE) sites in Japan. *Functional Plant Biology* 40, 148-159.
51. Hooper, D.U., Chapin, F.S., Ewel, J.J., Hector, A., Inchausti, P., Lavorel, S., Lawton, J.H., Lodge, D.M., Loreau, M., Naeem, S., Schmid, B., Setälä, H., Symstad, A.J., Vandermeer, J., Wardle, D.A. (2005). Effects of biodiversity on ecosystem functioning: a consensus of current knowledge. *Ecological monographs*, 75(1), 3-35.
52. Iizumi, T., Yokozawa, M., Sakurai, G., Travasso, M. I., Romanenkov, V., Oettli, P., Newby, T., Ishigooka, Y., Furuya, J. (2014). Historical changes in global yields: major cereal and legume crops from 1982 to 2006. *Global ecology and biogeography*, 23(3), 346-357.
53. Iizumi, T., & Ramankutty, N. (2016). Changes in yield variability of major crops for 1981-2010 explained by climate change. *Environmental Research Letters*, 11(3), 034003.
54. Iizumi, T., Furuya, J., Shen, Z., Kim, W., Okada, M., Fujimori, S., Hasegawa, T., Nishimori, M. (2017). Responses of crop yield growth to global temperature and socioeconomic changes. *Scientific Reports*, 7(1), 7800.
55. IPCC (2007). *Climate Change 2007: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. M.L. Parry, O.F. Canziani, J.P. Palutikof, P.J. van der Linden and C.E. Hanson, Eds., Cambridge University Press, Cambridge, UK, 976pp.
56. IPCC (2012). *Climate Change 2012: Managing the Risks of Extreme Events and Disasters to Advance Climate Change Adaptation. A Special Report of Working Groups I and II of the Intergovernmental Panel on Climate Change*. Field, C.B., V. Barros, T.F. Stocker, D. Qin, D.J. Dokken, K.L. Ebi, M.D. Mastrandrea, K.J. Mach, G.-K. Plattner, S.K. Allen, M. Tignor, and P.M. Midgley, Eds.. Cambridge University Press, Cambridge, UK, and New York, NY, USA, 582 pp.
57. IPCC (2014). *Climate Change 2014: Impacts, Adaptation, and Vulnerability. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. Field, C.B., V.R. Barros, D.J. Dokken, K.J. Mach, M.D. Mastrandrea, T.E. Bilir, M. Chatterjee, K.L. Ebi, Y.O. Estrada, R.C. Genova, B. Girma, E.S. Kissel, A.N. Levy, S. MacCracken, P.R. Mastrandrea, and L.L. White, Eds. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 1132 pp.
58. Iqbal, M.M., Goheer, M.A., Khan, A.M. (2009). Climate-change Aspersions on Food Security of Pakistan. *Science Vision*, Vol.15 No.1.
59. Jaggard, K.W., Qi, A., & Ober, E.S. (2010). Possible changes to arable crop yields by 2050. *Philosophical Transactions of the Royal Society of London B: Biological Sciences*, 365(1554), 2835-2851.
60. Khush, G.S. (1999). Green revolution: preparing for the 21st century. *Genome*, 42(4), 646-655.
61. Kimball, B.A., & Idso, S.B. (1983). Increasing atmospheric CO₂: effects on crop yield, water use and climate. *Agricultural water management*, 7(1-3), 55-72.

62. Kramer, P.J., & Boyer, J.S. (1995). *Water relations of plants and soils*. Academic press.
63. Leakey, A.D.B., Ainsworth, E.A., Bernacchi, C.J., Alistair, R., Long, S.P., Ort, D.R. (2009). Elevated CO₂ effects on plant carbon, nitrogen, and water relations: six important lessons from FACE. *Journal of Experimental Botany* 60, 2859-2876.
64. Li, S., Wheeler, T., Challinor, A., Lin, E., Ju, H. & Xu, Y. (2010) The observed relationships between wheat and climate in China. *Agricultural and Forest Meteorology*, 150, 1412-1419.
65. Lin, M., & Huybers, P. (2012). Reckoning wheat yield trends. *Environmental Research Letters*, 7(2), 024016.
66. Liebig, J. (1840). *Die organische Chemie in ihrer Anwendung auf Agricultur und Physiologie* (Organic chemistry in its applications to agriculture and physiology). Friedrich Vieweg und Sohn Publ. Co., Braunschweig, Germany.
67. Lima, M., Marquet, P.A., & Jaksic, F.M. (1999). El Niño events, precipitation patterns, and rodent outbreaks are statistically associated in semiarid Chile. *Ecography*, 22(2), 213-218.
68. Lima, M., & Berryman, A. (2006). Predicting nonlinear and non-additive effects of climate: the Alpine ibex revisited. *Climate Research*, 32(2), 129-135.
69. Lobell, D.B., & Field, C.B. (2007). Global scale climate-crop yield relationships and the impacts of recent warming. *Environmental research letters*, 2(1), 014002.
70. Lobell, D.B., Burke, M.B., Tebaldi, C., Mastrandrea, M.D., Falcon, W.P., & Naylor, R.L. (2008). Prioritizing climate change adaptation needs for food security in 2030. *Science*, 319(5863), 607-610.
71. Lobell, D.B., & Burke, M.B. (2008). Why are agricultural impacts of climate change so uncertain? The importance of temperature relative to precipitation. *Environmental Research Letters*, 3(3), 034007.
72. Lobell, D.B., Cassman, K.G., & Field, C.B. (2009). Crop yield gaps: their importance, magnitudes, and causes. *Annual review of environment and resources*, 34.
73. Lobell, D.B., & Burke, M.B. (2010). On the use of statistical models to predict crop yield responses to climate change. *Agricultural and Forest Meteorology*, 150(11), 1443-1452.
74. Lobell, D.B., Schlenker, W., & Costa-Roberts, J. (2011a). Climate trends and global crop production since 1980. *Science*, 333(6042), 616-620.
75. Lobell, D.B., Banziger, M., Magorokosho, C. & Vivek, B. (2011b). Nonlinear heat effects on African maize as evidenced by historical yield trials. *Nature Climate Change*, 1(1), 42-45.
76. Lobell, D.B., & Gourdji, S.M. (2012). The influence of climate change on global crop productivity. *Plant Physiology*, 160(4), 1686-1697.
77. Lobell, D.B., Sibley, A., & Ortiz-Monasterio, J.I. (2012). Extreme heat effects on wheat senescence in India. *Nature Climate Change*, 2(3), 186-189.
78. Lobell, D.B. (2012). The case of the missing wheat. *Environmental Research Letters*, 7(2), 021002.
79. Lobell, D.B., Hammer, G.L., McLean, G., Messina, C., Roberts, M.J. & Schlenker, W. (2013). The critical role of extreme heat for maize production in the United States. *Nature Climate Change*, 3, 497-501.
80. Long, S.P., Ainsworth, E.A., Leakey, A.D., Nösberger, J., & Ort, D.R. (2006). Food for thought: lower-than-expected crop yield stimulation with rising CO₂ concentrations. *Science*, 312(5782), 1918-1921.
81. MAGRAMA (2008) http://www.mapama.gob.es/app/materialvegetal/docs/FAO_estadistica_maiz_grano_2008.pdf [Acceso 1 enero 2018]
82. MAGRAMA (2018) <http://www.mapama.gob.es/es/desarrollo-rural/temas/gestion-sostenible-regadios/> [Acceso 1 enero 2018]
83. Manea, A., M.R. Leishman, & Downey, P.O. (2011) Exotic C4 Grasses Have Increased Tolerance to Glyphosate under Elevated Carbon Dioxide. *Weed Science*, 59, 28-36.

84. Marshall, E.J.P., Brown, V.K., Boatman, N.D., Lutman, P.J.W., Squire, G.R., & Ward, L.K. (2003). The role of weeds in supporting biological diversity within crop fields. *Weed research*, 43(2), 77-89.
85. McGrath, J.M., & Lobell, D.B. (2011). An independent method of deriving the carbon dioxide fertilization effect in dry conditions using historical yield data from wet and dry years. *Global Change Biology*, 17(8), 2689-2696.
86. Milly, P.C.D., Wetherald, R.T., Dunne, K.A., & Delworth, T.L. (2002). Increasing risk of great floods in a changing climate. *Nature*, 415(6871), 514.
87. Min, S.K., Zhang, X., Zwiers, F.W., & Hegerl, G.C. (2011). Human contribution to more-intense precipitation extremes. *Nature*, 470(7334), 378-381.
88. Moriondo, M., Giannakopoulos, C., & Bindi, M. (2011). Climate change impact assessment: the role of climate extremes in crop yield simulation. *Climatic Change*, 104(3-4), 679-701.
89. Mueller, N.D., Gerber, J.S., Johnston, M., Ray, D.K., Ramankutty, N., & Foley, J.A. (2012). Closing yield gaps through nutrient and water management. *Nature*, 490(7419), 254-257.
90. Müller, C., & Robertson, R.D. (2014). Projecting future crop productivity for global economic modeling. *Agricultural Economics*, 45(1), 37-50.
91. Murdoch, W.W. (1994). Population regulation in theory and practice. *Ecology*, 75(2), 271-287.
92. Oerke, E.C. (2006). Crop losses to pests. *The Journal of Agricultural Science*, 144(1), 31-43.
93. Olesen, J.E., Bindi, M. (2004) Agricultural impacts and adaptations to climate change in Europe. *Farm Policy Journal* 1:36-46
94. Paine, C.E., Marthens, T.R., Vogt, D.R., Purves, D., Rees, M., Hector, A., & Turnbull, L. A. (2012). How to fit nonlinear plant growth models and calculate growth rates: an update for ecologists. *Methods in Ecology and Evolution*, 3(2), 245-256.
95. Peng, S., Huang, J., Sheehy, J.E., Laza, R.C., Visperas, R.M., Zhong, X., Centeno, G.S., Khush, G.S. and Cassman, K.G. (2004). Rice yields decline with higher night temperature from global warming. *Proceedings of the National Academy of Sciences of the USA* 101 : 9971-9975.
96. Piao, S., Ciais, P., Huang, Y., Shen, Z., Peng, S., Li, J., Zhou, L., Liu, H., Ma, Y., Ding, Y, Friedlingstein, P., Liu, C., Tan, K., Yu, Y., Zhan, T., Fang, J. (2010). The impacts of climate change on water resources and agriculture in China. *Nature*, 467(7311), 43-51.
97. Pollnac, F.W., Maxwell, B.D., & Menalled, F.D. (2009). Weed community characteristics and crop performance: a neighbourhood approach. *Weed research*, 49(3), 242-250.
98. Porter, J.R., & Gawith, M. (1999). Temperatures and the growth and development of wheat: a review. *European Journal of Agronomy*, 10(1), 23-36.
99. Porter, J.R. & Semenov, M.A. (2005). Crop responses to climatic variation. *Philosophical Transactions of the Royal Society of Biological Sciences*, 360(1463).
100. Porter, J.R., Xie, L., Challinor, A.J., Cochrane, K., Howden, S.M., Iqbal, M.M., Lobell, D.B., Travasso, M.I. (2014). *Chapter 7: Food security and food production systems*. Cambridge University Press.
101. Porwollik, V., Müller, C., Elliott, J., Chryssanthacopoulos, J., Iizumi, T., Ray, D.K., Ruane, A.C., Arneth, A., Balkovic, J., Ciais, P., Deryng, D., Folberth, C., Izaauralde, R.C., Jones, C.D., Khabarov, N., Lawrence, P.J., Liu, W., Pugh, T.A.H., Reddy, A., Sakurai, G., Schmid, E., Wang, X., de Wit, A., Wu, X. (2017). Spatial and temporal uncertainty of crop yield aggregations. *European Journal of Agronomy*, 88, 10-21.
102. Qaderi, M. M., & Reid, D. M. (2009). Crop responses to elevated carbon dioxide and temperature. In *Climate Change and Crops* (pp. 1-18). Springer Berlin Heidelberg.
103. Rapoport, E.H. (1991). Tropical versus temperate weeds: a glance into the present and future. *Ecology of biological invasion in the tropics*, 11-51.

104. Ray, D.K., Ramankutty, N., Mueller, N.D., West, P.C., & Foley, J.A. (2012). Recent patterns of crop yield growth and stagnation. *Nature communications*, 3, 1293.
105. Ray, D.K., Mueller, N.D., West, P.C., & Foley, J.A. (2013). Yield trends are insufficient to double global crop production by 2050. *PloS one*, 8(6), e66428.
106. Ray, D.K., Gerber, J.S., MacDonald, G.K., & West, P.C. (2015). Climate variation explains a third of global crop yield variability. *Nature communications*, 6.
107. Reynolds, M.P., Rajaram, S., & Sayre, K.D. (1999). Physiological and genetic changes of irrigated wheat in the post-green revolution period and approaches for meeting projected global demand. *Crop Science*, 39(6), 1611-1621.
108. Rötter, R.P., Carter, T.R., Olesen, J.E., Porter, J.R. (2011) Crop-climate models need an overhaul. *Nature Climate Change* 1(4):175-177.
109. Rosenzweig, C., & Parry, M.L. (1994). Potential impact of climate change on world food supply. *Nature*, 367(6459), 133-138.
110. Rosenzweig, C., Tubiello, F.N., Goldberg, R., Mills, E., & Bloomfield, J. (2002). Increased crop damage in the US from excess precipitation under climate change. *Global Environmental Change*, 12(3), 197-202.
111. Rosenzweig, C., Jones, J.W., Hatfield, J.L., Ruane, A.C., Boote, K.J., Thorburn, P., Antle, J.M., Nelson, G.C., Porter, C., Janssen, S. Asseng, S., Basso, B., Ewert, F., Wallach, D., Baigorria, G., & Winter, J.M. (2013) The Agricultural Model Intercomparison and Improvement Project (AgMIP): Protocols and pilot studies. *Agricultural and Forest Meteorology*, 170, 166-182.
112. Rosenzweig, C., Elliott, J., Deryng, D., Ruane, A.C., Müller, C., Arneth, A., & J.W. Jones (2014). Assessing agricultural risks of climate change in the 21st century in a global gridded crop model intercomparison. *Proceedings of the National Academy of Sciences*, 111(9), 3268-3273.
113. Royama, T. (1977). Population persistence and density dependence. *Ecological monographs*, 47(1), 1-35.
114. Royama, T. (1992) *Analytical Population Dynamics*. Springer, New York, NY. 371 pages.
115. Sadras, V. (2015). *Yield gap analysis of field crops: Methods and case studies*. Food and Agriculture Organization of the United Nations.
116. Schär, C., Vidale, P.L., Lüthi, D., Frei, C., Häberli, C., Liniger, M.A., Appenzeller, C. (2004) The role of increasing temperature variability in European summer heatwaves. *Nature* 427:332-336
117. Schlenker, W., & Roberts, M.J. (2009). Nonlinear temperature effects indicate severe damages to US crop yields under climate change. *Proceedings of the National Academy of sciences*, 106(37), 15594-15598.
118. Schlenker, W., & Lobell, D.B. (2010). Robust negative impacts of climate change on African agriculture. *Environmental Research Letters*, 5(1), 014010.
119. Schmidhuber, J., & Tubiello, F.N. (2007). Global food security under climate change. *Proceedings of the National Academy of Sciences*, 104(50), 19703-19708.
120. Semenov M.A & Porter J.R. (1995) Climatic variability and the modelling of crop yields. *Agricultural and Forest Meteorology*. 73:265-283.
121. Shimono, H., Okada, M., Yamakawa, Y., Nakamura, H., Kobayashi, K. & Hasegawa, T. (2008) Rice yield enhancement by elevated CO₂ is reduced in cool weather. *Global Change Biology*, 14, 276-284.
122. Siebert, S. & Döll, P. (2010). Quantifying blue and green virtual water contents in global crop production as well as potential production losses without irrigation. *Journal of Hydrology*. 384, 198-217.
123. Slingo, J.M., Challinor, A.J., Hoskins, B.J., & Wheeler, T.R. (2005). Introduction: food crops in a changing climate. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 360(1463), 1983-1989.
124. Stone, P. (2001) *The effects of heat stress on cereal yield and quality*. In AS Basra, ed, *Crop Responses and Adaptations to Temperature Stress*. Food Products Press, Binghamton, NY, pp 243-291.

125. Sun, B.J., Van Kooten, G.C. (2013) Weather effects on maize yields in northern China. *The Journal of Agricultural Science*. 1-11.
126. Tebaldi, C., Hayhoe, K., Arblaster, J.M., & Meehl, G.A. (2006). Going to the extremes. *Climatic change*, 79(3-4), 185-211.
127. Teixeira, E.I., Fischer, G., van Velthuisen, H., Walter, C., & Ewert, F. (2013). Global hot-spots of heat stress on agricultural crops due to climate change. *Agricultural and Forest Meteorology*, 170, 206-215.
128. Tester, M., & Langridge, P. (2010). Breeding technologies to increase crop production in a changing world. *Science*, 327(5967), 818-822.
129. Tilman, D., Balzer, C., Hill, J., Befort, B.L. (2011) Global food demand and the sustainable intensification of agriculture. *Proceedings of the National Academy of Sciences of USA* 108: 20260-20264.
130. Tollenaar, M. (1989). Genetic improvement in grain yield of commercial maize hybrids grown in Ontario from 1959 to 1988. *Crop Science*, 29(6), 1365-1371.
131. Urban, D., Roberts, M.J., Schlenker, W., & Lobell, D.B. (2012). Projected temperature changes indicate significant increase in interannual variability of US maize yields. *Climatic change*, 112(2), 525-533.
132. van Ittersum, M.K., Cassman, K.G., Grassini, P., Wolf, J., Tittmonell, P., & Hochman, Z. (2013). Yield gap analysis with local to global relevance—a review. *Field Crops Research*, 143, 4-17.
133. Verón, S.R., de Aballeyra, D., & Lobell, D.B. (2015). Impacts of precipitation and temperature on crop yields in the Pampas. *Climatic change*, 130(2), 235-245.
134. von Bertalanffy, L. (1968). *General system theory*. New York, 41973(1968), 40.
135. Watt, A.D., Stork, N.E., & Hunter, M.D. (Eds.). (1997). *Forests and Insects*, London: Chapman & Hall, pp. 229-247
136. Wassmann, R., Jagadish, S.V.K., Sumfleth, K., Pathak, H., Howell, G., Ismail, A., ... & Heuer, S. (2009a). Regional vulnerability of climate change impacts on Asian rice production and scope for adaptation. *Advances in Agronomy*, 102, 91-133.
137. Wassmann, R., Jagadish, S.V.K., Heuer, S., Ismail, A., Redona, E., Serraj, R., Singh, R.K., Howell, G., Pathak, H. & Sumfleth, K. (2009b). Climate change affecting rice production: the physiological and agronomic basis for possible adaptation strategies. *Advances in agronomy*, 101, 59-122.
138. Welch, J.R., Vincent, J.R., Auffhammer, M., Moya, P.F., Dobermann, A., & Dawe, D. (2010). Rice yields in tropical/subtropical Asia exhibit large but opposing sensitivities to minimum and maximum temperatures. *Proceedings of the National Academy of Sciences*, 107(33), 14562-14567.
139. Wheeler, T.R., Crauford, P.Q., Ellis, R.H., Porter, J.R., Vara Prasad, P.V. (2000) Temperature variability and the yield of annual crops. *Agriculture, Ecosystems & Environment*. 82:159-167.
140. Wheeler, T., & Von Braun, J. (2013). Climate change impacts on global food security. *Science*, 341(6145), 508-513.
141. White, J.W., Hoogenboom, G., Kimball, B.A., Wall, G.W. (2011) Methodologies for simulating impacts of climate change on crop production. *Field Crops Research*. 124(3):357-368.
142. World Bank (2018) <http://www.worldbank.org/en/news/feature/2013/10/16/food-production-trade-latin-america-caribbean-future> [Acceso 1 enero 2018]
143. Zhang, T., Zhu, J., Yang, X., & Zhang, X. (2008). Correlation changes between rice yields in North and Northwest China and ENSO from 1960 to 2004. *Agricultural and Forest Meteorology*, 148(6), 1021-1033.
144. Zhang, T., Zhu, J., & Wassmann, R. (2010). Responses of rice yields to recent climate change in China: an empirical assessment based on long-term observations at different spatial scales (1981-2005). *Agricultural and Forest Meteorology*, 150(7), 1128-1137.
145. Zhao, C., Liu, B., Piao, S., Wang, X., Lobell, D.B., Huang, Y., Huan M., Yao, Y., Bassu, S., Ciais, P., Durand, J.L., Elliott, J., Ewert, F., Janssens, I.A., Li, T., Lin, E.,

- Liu, Q., Martre, P., Müller, C., Peng, S., Peñuelas, J., Ruane, A.C., Wallach, D., Wang, T., Wu, D., Liu, Z., Zhuh, Y., Zhu, Z., Asseng, S. (2017). Temperature increase reduces global yields of major crops in four independent estimates. *Proceedings of the National Academy of Sciences*, 201701762.
146. Ziska, L.H. (2003). Evaluation of yield loss in field-grown sorghum from a C3 and C4 weed as a function of increasing atmospheric carbon dioxide. *Weed Science*. 51:914-918.
 147. Ziska, L.H., Tomecek, M.B., & Gealy, D.R. (2010). Competitive interactions between cultivated and red rice as a function of recent and projected increases in atmospheric carbon dioxide. *Agronomy journal*, 102(1), 118-123.
 148. Zwiers, F.W., Zhang, X., & Feng, Y. (2011). Anthropogenic influence on long return period daily temperature extremes at regional scales. *Journal of Climate*, 24(3), 881-892.

Apéndice

A1. Series temporales vs Modelos dinámicos

Nuestros modelos se basan en los modelos clásicos de series temporales pero incluyen algunas otras ventajas. A continuación explicaré la equivalencia entre nuestros modelos dinámicos y los modelos clásicos de series temporales.

Partimos del modelo de proceso endógeno puro de orden h : $R[t] = f(Y[t], Y[t-1], \dots, Y[t-h+1])$ (denominada función R), al cual le hemos incluido las perturbaciones exógenas z_t debidas a factores climáticos o malezas como efectos aditivos (verticales) y no aditivos (laterales, no lineales), z_t y z'_t respectivamente: $R_t = f(Y - z'[t]) + z[t]$, donde Y es el conjunto de valores de rendimiento del cultivo en el tiempo ($Y[t], Y[t-1], \dots, Y[t-h+1]$). Cabe notar que este proceso se convierte en un proceso estocástico en el tiempo si $z[t]$ o $z'[t]$ contiene aleatoriedad (Royama 1992).

Con el fin de mantener la generalidad del argumento, suponemos que z_t está de alguna manera autocorrelacionado, y empleamos el esquema clásico ampliamente utilizado en los análisis de series de tiempo: $z[t] = u[t] + b[1] * u[t-1] + \dots + b[k] * u[t-k]$, donde u son números aleatorios distribuidos de forma idéntica (iid). Este esquema se conoce como el proceso de media móvil de orden k (MA (k)).

De ahora en adelante, solo consideraremos el efecto de perturbación aditivo (vertical) como ejemplo, que es más sencillo. Así, el proceso endógeno / exógeno de orden (h, k) que estudiamos es: $R[t] = f(Y[t], Y[t-1], \dots, Y[t-h+1]) + b[1] * u[t-1] + \dots$ (h, k) el cual corresponde al modelo lineal de series temporales conocido como proceso de media móvil autorregresiva de orden (h, k), ARMA (h, k). Cuando $k = 0$, este modelo se convierte en un modelo autorregresivo de orden h , AR (h).

Los modelos clásicos de series temporales son recursos descriptivos prácticos y útiles que permiten representar el efecto autocorrelacionado y / o autorregresivo de un factor sin necesidad de especificar su estructura. El modelo lineal clásico discutido anteriormente es el más simple matemáticamente y el más fácil de analizar.

Desde un punto de vista ecológico, sin embargo, el modelo tiene una propiedad poco realista: su tasa de cambio es ilimitada. Sin embargo, la dinámica de rendimiento del cultivo estaría mejor representada por algún tipo de modelo no lineal cuya tasa de cambio esté limitada dentro de ciertos rangos biológicos. Una razón principal para la no linealidad es que los cultivos tienen una capacidad de producción limitada. Esta tasa máxima de cambio en el rendimiento de los cultivos (r_{max}), se debe a una capacidad limitada para plantar, a una biomasa máxima limitada y a una captación máxima de recursos limitada. Por lo tanto, $R[t]$ en un sistema real debe ser una función no lineal del log rendimiento Y . Esto implica que la función R es asimétrica alrededor del punto de equilibrio y a su vez, provoca un ciclo asimétrico en las series, tanto sobre la media como sobre el pico del ciclo.

La versión generalizada de la forma exponencial del modelo discreto logístico posee estas características. Por ejemplo, una simple no linealización del modelo AR(1) es el modelo logístico de primer orden: $R[t] = r_{max} - \exp(a * Y[t-1]) + u[t]$

Aquí, diferencia de los modelos clásicos de series de tiempo lineales, hemos utilizado modelos no lineales para modelar la función f y los modelos lineales para el factor exógeno z_t (es decir $z[t] = b * Z[t]$), entonces:
 $R[t] = r_{max} - \exp(a * Y[t-d]) + z[t]$ para modelos aditivos (verticales)
 $R[t] = r_{max} - \exp(a * Y[t-d] + z'[t])$ para los modelos no aditivos (laterales)

El enfoque clásico de series temporales es útil para fines diagnósticos pero no para construir modelos explicativos, que creemos que deberían tener una derivación ecológica, como es el caso de la ecuación logística (Royama 1992).

Efectos vertical, lateral y no lineal

Tanto las perturbaciones aditivas (verticales) como las no aditivas (laterales) se pueden denominar perturbaciones lineales en la medida en que los cambios en el factor exógeno Z no influyen en la forma relativa de la curva de función R , sólo trasladan las coordenadas ($R[t]$, $Y[t-1]$). Si hay una interacción entre Z y el nivel de rendimiento Y (efecto no aditivo), los cambios en Z desplazan las coordenadas ($R[t]$, $Y[t-1]$) de la curva lateralmente a lo largo del eje $Y[t-1]$. Y si un factor exógeno tiene un efecto de perturbación aditivo o independiente sobre los niveles de rendimiento de la cosecha, entonces la posición relativa de la curva en el plano ($R[t]$, $Y[t-1]$) se desplaza hacia arriba o hacia abajo cuando Z cambia (vertical).

El tipo de perturbación no lineal sí modifica la forma de la función R , la puede volver más o menos cóncava o convexa.

Con respecto al cambio en la estabilidad del equilibrio, las perturbaciones exógenas que actúan sobre la tasa máxima de cambio per

cápita, r_{\max} y la capacidad de carga, K , provocan cambios en la amplitud y el período de oscilación y potencialmente desestabilizan el equilibrio.

En los modelos aditivos (verticales), que desplazan la función R hacia arriba o hacia abajo, la tasa máxima de cambio (r_{\max}) se ve alterada. Berryman (1999) indicó que el período de oscilaciones está determinado por el producto " $r_{\max} * a$ " (donde " a " es el parámetro no linealidad de la curva). Las simulaciones con modelos logísticos mostraron que un mayor " r_{\max} ", para el mismo valor " a " y el retardo de tiempo " d ", conducen a ciclos de amplitud y período crecientes y potencialmente desestabilizan el equilibrio. Por lo tanto, las perturbaciones verticales causan cambios en el patrón de oscilación alrededor del equilibrio, a través de los efectos sobre " r_{\max} ";

Por ejemplo, los aumentos graduales y persistentes del dióxido de carbono atmosférico y de otros gases "invernadero" podrían causar oscilaciones cada vez más violentas o un cambio gradual en la densidad media de las poblaciones.

Las perturbaciones laterales no cambian el patrón de dinámica alrededor del equilibrio, ya que los parámetros sensibles " r_{\max} " y " a " no se ven afectados.

A2. Material complementario de los artículos publicados en esta tesis.

SI1. Crop production structure and stability under climate change in South America

DATA ACCESSIBILITY

-Historical crop yield data for Argentina (1969/70-2010/11; <http://www.siiia.gov.ar>), Uruguay (1960/61-2010/11, <http://www.mgap.gub.uy/portal/hgxpp001.aspx?7,1,12,O,S,0,MNU;E;9;1;MNU;;>), Chile (1979/80-2010/11; <http://www.odepa.cl>) and Brazil (variable#, <http://www.conab.gov.br/>).

- Global Historical Climatology Network (GHCND) data on monthly temperature and rainfall (<http://www.ncdc.noaa.gov/cdo-web/datasets>). For sites with missing data (Valparaiso, Santiago, Chillán, Valdivia) we obtained Chile's weather annuals in climatologic yearbooks (<http://www.meteochile.gob.cl>).

-Country's data on the emissions of CO₂ (kt) were taken from the World Bank's World Development Indicators (WDI; <http://data.worldbank.org/data-catalog/world-development-indicators>).

Appendix S1.

TABLE S1. Summary statistics of nonlinear logistic models fit to eight major crops and regional time series in South America (1969/70-2010/11, Argentina; 1960/61-2010/11, Uruguay; 1979/80-2010/11, Chile and about 1976/77-2010/2011, Brazil). We evaluated pure endogenous processes, and impacts of temperature, rainfall and CO_2 emission on crop yields by lateral, vertical or nonlinear effects (see Appendix S2). Estimates of the percentage of total crop production in South America ($\%Total$), maximum finite reproductive rate (r_{max}), parameters c and a , coefficients for different exogenous effects (b), pseudo-coefficient of determination (R^2) and Akaike information criterion (AIC).

Country	State or region	%tot	Model	Climate or CO_2	R^2	AIC	r_{max}	a	b	c
Rice										
Brazil	Rio Grande do Sul	52.4	endogenous		0.54	-153.64	0.29	4.09**		-40.74**
Brazil	Santa Catarina	7.40	endogenous		0.38	-177.37	0.23	3.16**		-31.73**
Brazil	Mato Grosso	5.00	endogenous		0.29	-150.14	0.35	1.68**		-15.66**
Uruguay	Soriano (N=45)	6.30	vertical	TPCPt	0.44	-154.64	0.36	4.57	-0.04*	-45.82
Uruguay	Soriano (N=45)	6.30	lateral	TPCPt	0.45	-154.86	0.36	1.81**	0.10*	-18.95**
Uruguay	Soriano (N=45)	6.30	lateral	EMXPt	0.45	-155.25	0.36	1.77**	0.20*	-19.04**
Uruguay	Soriano (N=45)	6.30	endogenous		0.34	-169.43	0.36	1.91**		-19.31**
Argentina	Entre Ríos	3.40	endogenous		0.51	-165.22	0.33	3.17**		-31.72**
Argentina	Corrientes (N=24)	3.20	lateral	TPCPt	0.64	-89.84	0.31	3.07**	0.17*	-31.02**
Argentina	Corrientes (N=24)	3.20	endogenous		0.53	-85.56	0.31	3.43**		-33.35**
Chile	Maule	0.60	lateral	MMNTt	0.54	-121.04	0.36	2.51**	-4.51*	7.94
Chile	Maule	0.60	no lineal	MMNTt	0.54	-121.09	0.36	6.89**	-0.93*	-13.24**
Chile	Maule	0.60	endogenous		0.47	-118.65	0.36	2.48**		-13.07**
Chile	Bío Bío	0.10	vertical	MMNTt	0.53	-100.49	0.45	0.07**	2.95**	2.32**
Chile	Bío Bío	0.10	lateral	MMNTt	0.51	-99.4	0.45	2.21**	-6.75**	20.09
Chile	Bío Bío	0.10	endogenous		0.39	-94.69	0.45	1.73**		-9.21**
Oat										
Brazil	Paraná	37.0	lateral	EMXTt	0.57	-49.21	0.75	1.24**	1.72*	-19.09**
Brazil	Paraná	37.0	endogenous		0.41	-44.79	0.75	1.04**		-9.03**
Brazil	Rio Grande do Sul	36.6	endogenous		0.49	-107.08	0.59	1.72**		-14.87**
Brazil	Santa Catarina	4.90	endogenous		0.32	-64.42	0.79	0.81**		-6.65**
Chile	Araucanía	4.20	lateral	MMXTt	0.42	-93.7	0.4	1.73**	5.09*	-33.37**

Chile	Araucania	4.20	endogenous		0.31	-90.11	0.4	1.59"		-8.21"
Argentina	Buenos Aires	4.00	endogenous		0.59	-139.82	0.48	2.68"		-23.39"
Chile	Bío Bío	1.50	endogenous		0.26	-84.43	0.41	1.33"		-6.81"
Uruguay	Soriano (N=48)	0.40	vertical	MMXTt_1	0.58	-151.86	0.51	0.13'	1.47'	0.99
Uruguay	Soriano (N=48)	0.40	lateral	MMXTt_1	0.58	-151.17	0.51	1.96"	-2.86'	-2.33
Uruguay	Soriano (N=48)	0.40	endogenous		0.50	-149.52	0.51	2.02"		-16.75"

Barley

Argentina	Buenos Aires	73.4	endogenous		0.43	-120.63	0.47	1.89"		-17.4"
Uruguay	Soriano	14.6	vertical	MMXTt_1	0.68	-108.57	1.1	2.75	-0.14"	-24.3
Uruguay	Soriano	14.6	vertical	EMXTt_1	0.68	-108.65	1.1	2.8	-0.14"	-24.7
Uruguay	Soriano	14.6	endogenous		0.47	-92.3	1.1	0.9"		-7.53"
Chile	Araucania	2.90	lateral	MMXTt	0.48	-82.41	0.56	1.62"	3.97'	-27.24"
Chile	Araucania	2.90	endogenous		0.4	-79.74	0.56	1.54"		-7.75"
Brazil	Rio Grande do Sul	2.60	vertical	MMNTt_1	0.73	-68.47	0.94	9.83'	-0.17"	-86.79'
Brazil	Rio Grande do Sul	2.60	vertical	EMNTt_1	0.72	-67.43	0.94	8.27'	-0.17"	-73.18'
Brazil	Rio Grande do Sul	2.60	endogenous		0.66	-64.88	0.94	1.28"		-11.06"
Brazil	Paraná	2.50	endogenous		0.33	-72.99	0.89	0.74"		-6.69"
Chile	Bío Bío	0.80	endogenous		0.36	-109.39	0.41	1.74"		-9.21"
Chile	Los Lagos	0.70	lateral	MMXTt	0.54	-85.29	0.69	1.26"	3.67'	-23.86"
Chile	Los Lagos	0.70	endogenous		0.44	-81.24	0.69	1.23"		-6.17"

Sunflower

Argentina	Buenos Aires	60.7	endogenous		0.33	-136.63	0.28	2.58"		-22.8"
Argentina	La Pampa	15.6	lateral	MMXTt	0.62	-130.2	0.74	1.63"	2.21"	-24.56"
Argentina	La Pampa	15.6	lateral	MNTMt	0.61	-129.34	0.74	1.66"	3.05'	-28.71"
Argentina	La Pampa	15.6	endogenous		0.55	-125.32	0.74	1.61"		-13.61"
Argentina	Chaco	12.1	endogenous		0.58	-94.04	1.09	1.16"		-9.42"
Argentina	Córdoba	4.7	endogenous		0.57	-118.61	0.58	1.94"		-16.79"
Argentina	Entre Ríos	2.5	lateral	MMNTt	0.62	-118.57	0.47	2.83"	3.09'	-38.66"
Argentina	Entre Ríos	2.5	endogenous		0.58	-116.48	0.47	2.65"		-22.58"
Brazil	Mato Grosso	1.40	endogenous		0.83	-61.44	0.19	8.46"		-72.05"
Uruguay	Soriano	1.30	vertical	EMXTt	0.61	-108.25	0.66	0.09"	1.84"	1.58"
Uruguay	Soriano	1.30	lateral	EMXTt	0.62	-108.91	0.66	1.29"	-2.91"	3.87
Uruguay	Soriano	1.30	endogenous		0.47	-106.25	0.66	1.49"		-12.02"
Brasil	Rio Grande do Sul	0.60	endogenous		0.44	-49.71	0.34	2.77"		-24.12"

Maize

Argentina	Córdoba	18,5	lateral	MMXTt	0.57	-109.87	0.64	1.08"	5.08"	-35.39"
Argentina	Córdoba	18,5	endogenous		0.4	-98.43	0.64	1.37"		-13.42"
Argentina	Buenos Aires	16.6	lateral	EMXTt	0.56	-122.72	0.56	1.91"	2.32'	-30.31"
Argentina	Buenos Aires	16.6	endogenous		0.51	-120.44	0.56	1.93"		-19.15"
Brasil	Paraná	8.30	endogenous		0.62	-66.98	0.52	2.47"		-23.81"
Argentina	Santa Fé	7.20	lateral	MMXTt	0.57	-118.65	0.83	1.03"	2.54"	-22.55"
Argentina	Santa Fé	7.20	endogenous		0.46	-111.66	0.83	1.16"		-11.35"
Brazil	Mato Grosso	5.50	endogenous		0.43	-79.03	0.25	3.32"		-31.88"







Brazil	Minas Gerais	4.00	endogenous		0.38	-101.74	0.16	4.88"		-47.39"
Brazil	Rio Grande do Sul	4.00	endogenous		0.54	-35.65	0.91	1.27"		-11.67"
Chile	O' Higgins	2.00	endogenous		0.33	-162.35	0.21	3.15"		-19.47"
Chile	Maule	1.00	endogenous		0.28	-103.43	0.4	1.53"		-8.95"
Uruguay	Soriano	0.70	vertical	EMNTt_1	0.68	-84.1	1.04	0.22"	0.72'	-0.4
Uruguay	Soriano	0.70	endogenous		0.55	-75.85	1.04	1.12"		-9.63"
Soybean										
Argentina	Córdoba	17.3	lateral	MMXTt	0.58	-114.3	0.73	1.20"	3.13"	-26.03"
Argentina	Córdoba	17.3	endogenous		0.47	-107.3	0.73	1.28"		-11.48"
Argentina	Buenos Aires	17.1	endogenous		0.49	-110.01	0.83	1.25"		-11.11"
Argentina	Santa Fé	14.2	lateral	EMNTt_1	0.65	-131.18	0.57	2.03"	-1.11'	-13.45"
Argentina	Santa Fé	14.2	endogenous		0.61	-128.87	0.57	2.2"		-19.99"
Brazil	Mato Grosso	9.80	endogenous		0.3	-179.63	0.21	2.93"		-27.69"
Brazil	Paraná (N=18)	6.90	vertical	EMXTt_1	0.53	-66.99	0.59	0.19"	1.1'	0.1
Brazil	Paraná (N=18)	6.90	lateral	EMXTt_1	0.53	-67.04	0.59	1.91"	-1.86'	-8.4
Brazil	Paraná (N=21)	6.90	vertical	EMXPt	0.57	-71.11	0.59	0.83"	0.11'	-7.15"
Brazil	Paraná (N=21)	6.90	lateral	EMXPt	0.57	-71.24	0.59	1.68"	-0.19'	-14.44"
Brazil	Paraná (N=18)	6.90	endogenous		0.33	-62.69	0.59	1.39"		-12.88"
Brazil	Paraná (N=21)	6.90	endogenous		0.45	-68.11	0.59	1.56"		-14.33"
Brazil	Rio Grande do Sul	6.40	endogenous		0.55	-68.79	1.03	1.13"		-9.59"
Uruguay	Soriano	1.20	vertical	CO2t	0.55	-98.41	1.1	0.44"	0.17'	-2.73"
Uruguay	Soriano	1.20	lateral	CO2t	0.55	-97.69	1.1	1.04"	-0.16'	-7.2"
Uruguay	Soriano	1.20	endogenous		0.49	-93.91	1.1	0.92"		-7.58"
Sorghum										
Argentina	Córdoba	17.4	lateral	MMXTt	0.62	-135.21	0.58	1.29"	4.55"	-34.86"
Argentina	Córdoba	17.4	endogenous		0.42	-120.33	0.58	1.47"		-14.33"
Argentina	Entre Ríos	11.9	lateral	MMXTt	0.68	-127.29	0.75	1.55"	3.12"	-29.8"
Argentina	Entre Ríos	11.9	endogenous		0.6	-120.57	0.75	1.67"		-15.7"
Argentina	Santa Fé	14.3	lateral	MMXTt	0.48	-143.14	0.4	1.86"	3.81"	-36.92"
Argentina	Santa Fé	14.3	endogenous		0.36	-140.8	0.4	1.77"		-17.49"
Argentina	Santiago del Estero	9.70	lateral	MNTMt	0.62	-93.24	1.36	0.92"	3.25"	-23.68"
Argentina	Santiago del Estero	9.70	endogenous		0.55	-88.29	1.36	0.88"		-7.61"
Argentina	Chaco	8.80	endogenous		0.63	-115.55	0.54	2.36"		-21.88"
Brazil	Goiás	8.20	endogenous		0.62	-97.08	0.67	1.86"		-16.57"
Argentina	Buenos Aires	6.40	lateral	EMXTt	0.51	-141.13	0.63	1.34"	1.86'	-22.14"
Argentina	Buenos Aires	6.40	endogenous		0.45	-137.87	0.63	1.44"		-14"
Brazil	Mato Grosso	3.40	endogenous		0.39	-91.29	0.69	1.13"		-10.11"
Uruguay	Soriano	3.50	endogenous		0.63	-118.86	0.93	1.47"		-13.14"
Brazil	Minas Gerais	2.90	vertical	EMXPt_1	0.62	-80.58	0.76	0.37"	0.29"	-2.46'
Brazil	Minas Gerais	2.90	lateral	EMXPt_1	0.61	-79.91	0.76	1.08"	-0.39"	-7.68"
Brazil	Minas Gerais	2.90	endogenous		0.44	-72.27	0.76	1.15"		-4.39"
Wheat										
Argentina	Buenos Aires	42.4	lateral	MMXTt	0.62	-147.13	0.46	2.55"	3.37"	-39.36"







Argentina	Buenos Aires	42.4	endogenous		0.51	-138.52	0.46	2.46**		-22.36**
Argentina	Córdoba	10.1	vertical	MNTMt_1	0.54	-94.73	0.78	0.06	3.35*	2.33
Argentina	Córdoba	10.1	vertical	CO2t_1	0.6	-96.72	0.78	8.17	-0.06**	-72.66
Argentina	Córdoba	10.1	endogenous		0.49	-92.75	0.78	1.34**		-11.79**
Argentina	Santa Fé (N=40)	9.30	lateral	MMNTt_1	0.66	-121.00	0.37	2.91**	-5.03**	-3.10
Argentina	Santa Fé (N=40)	9.30	endogenous		0.52	-109.95	0.37	3.28**		-29.76**
Brazil	Paraná	7.30	vertical	MMXTt_1	0.59	-56.95	0.99	0.06*	1.9**	1.8**
Brazil	Paraná	7.30	lateral	MMXTt_1	0.60	-57.46	0.99	0.63**	-1.91**	3.84
Brazil	Paraná	7.30	endogenous		0.27	-47.41	0.99	0.64*		-5.45*
Brazil	Rio Grande do Sul	5.70	lateral	TPCPt	0.61	-48.15	0.98	1.1**	-0.05*	-9.01**
Brazil	Rio Grande do Sul	5.70	endogenous		0.51	-45.25	0.98	1**		-4.56**
Argentina	Entre Ríos	5.30	endogenous		0.43	-90.29	0.71	1.28**		-11.46**
Uruguay	Soriano	4.70	vertical	MMXTt_1	0.64	-123.26	0.61	3.89	-0.08**	-34.53
Uruguay	Soriano	4.70	vertical	EMXTt_1	0.64	-122.96	0.61	3.86	-0.07**	-34.32
Uruguay	Soriano	4.70	endogenous		0.4	-106.97	0.61	1.42**		-12.58**
Chile	Araucania	3.20	endogenous		0.4	-107.61	0.39	2.16**		-10.9**
Chile	Bío Bío	2.10	lateral	MMXTt	0.57	-114.57	0.4	2.35**	3.55*	-28.79**
Chile	Bío Bío	2.10	no lineal	MMXTt	0.57	-114.48	0.4	-1.36	0.77*	-11.71**
Chile	Bío Bío	2.10	endogenous		0.48	-110.59	0.4	2.55**		-12.63**







NOTE: * $P < 0.05$, ** $P < 0.01$, Sample size (N) was indicated if no available data were detected. CO_2 annual carbon dioxide emission (kt , country-level emissions), and summary statistics of the growing season weather: *EMNT* extreme minimum temperature ($^{\circ}C$), *EMXT* extreme maximum temperature ($^{\circ}C$), *MMNT* mean minimum temperature ($^{\circ}C$), *MMXT* mean maximum temperature ($^{\circ}C$), *MNTM* mean temperature ($^{\circ}C$), *EMXP* extreme maximum daily precipitation total (l/m^2), *TPCP* total precipitation ($L\ m^{-2}$).















FIGURE S1. Definition of study region. Not all crops are present in all study regions.



















































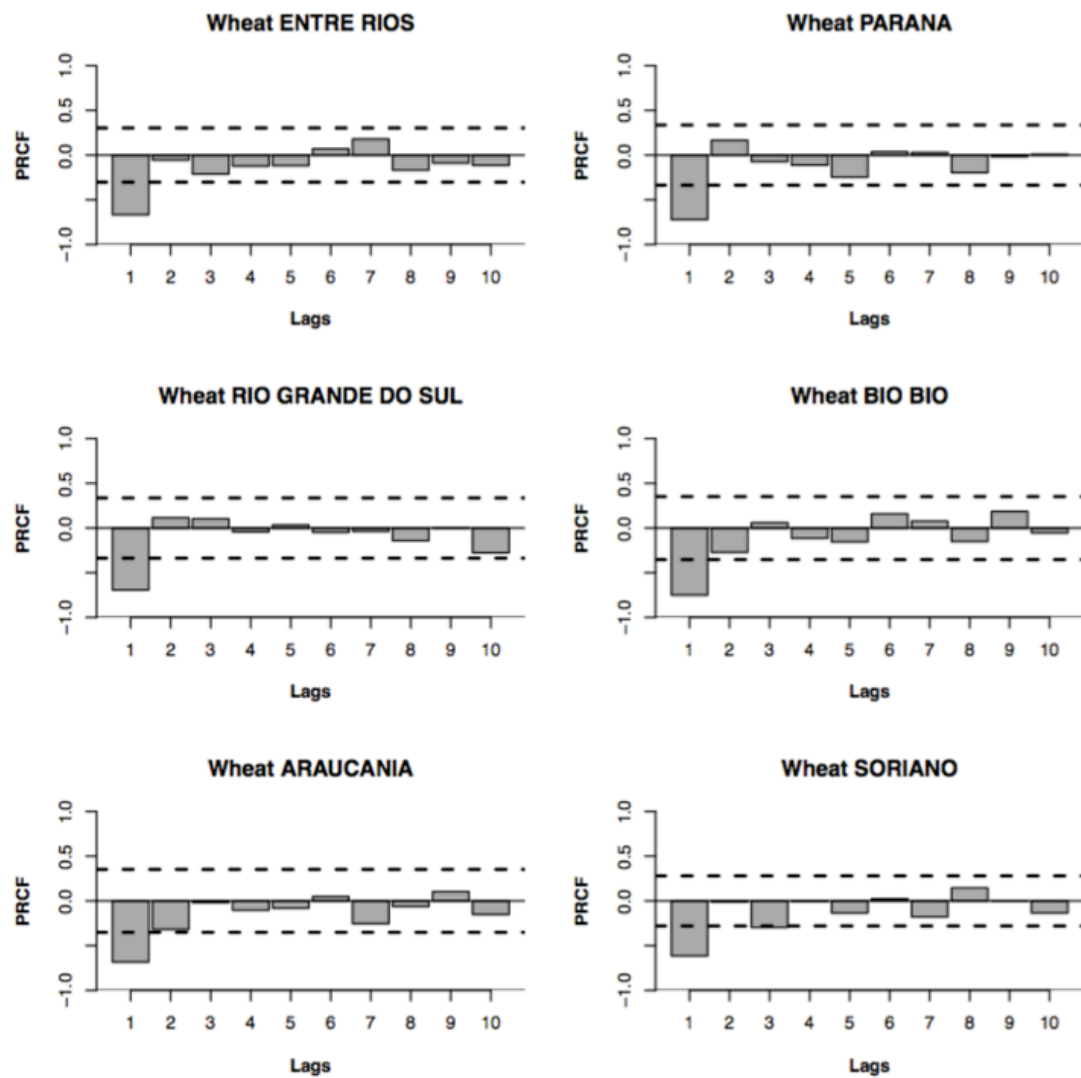




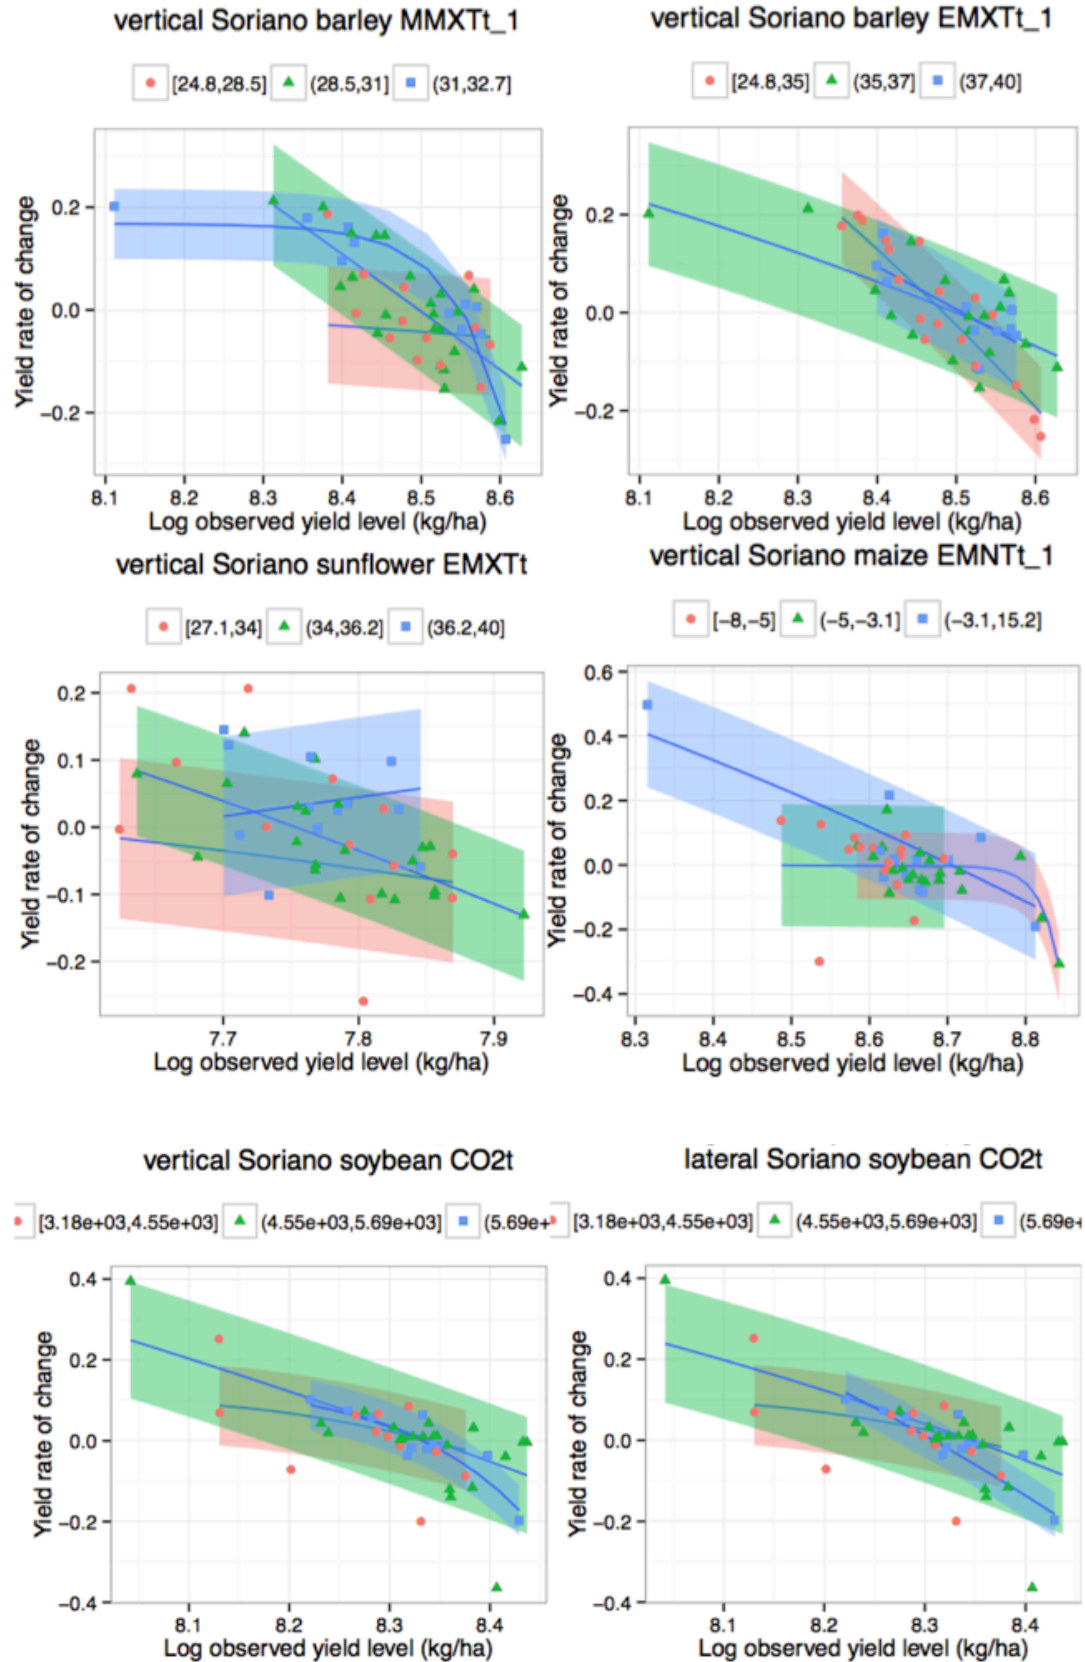
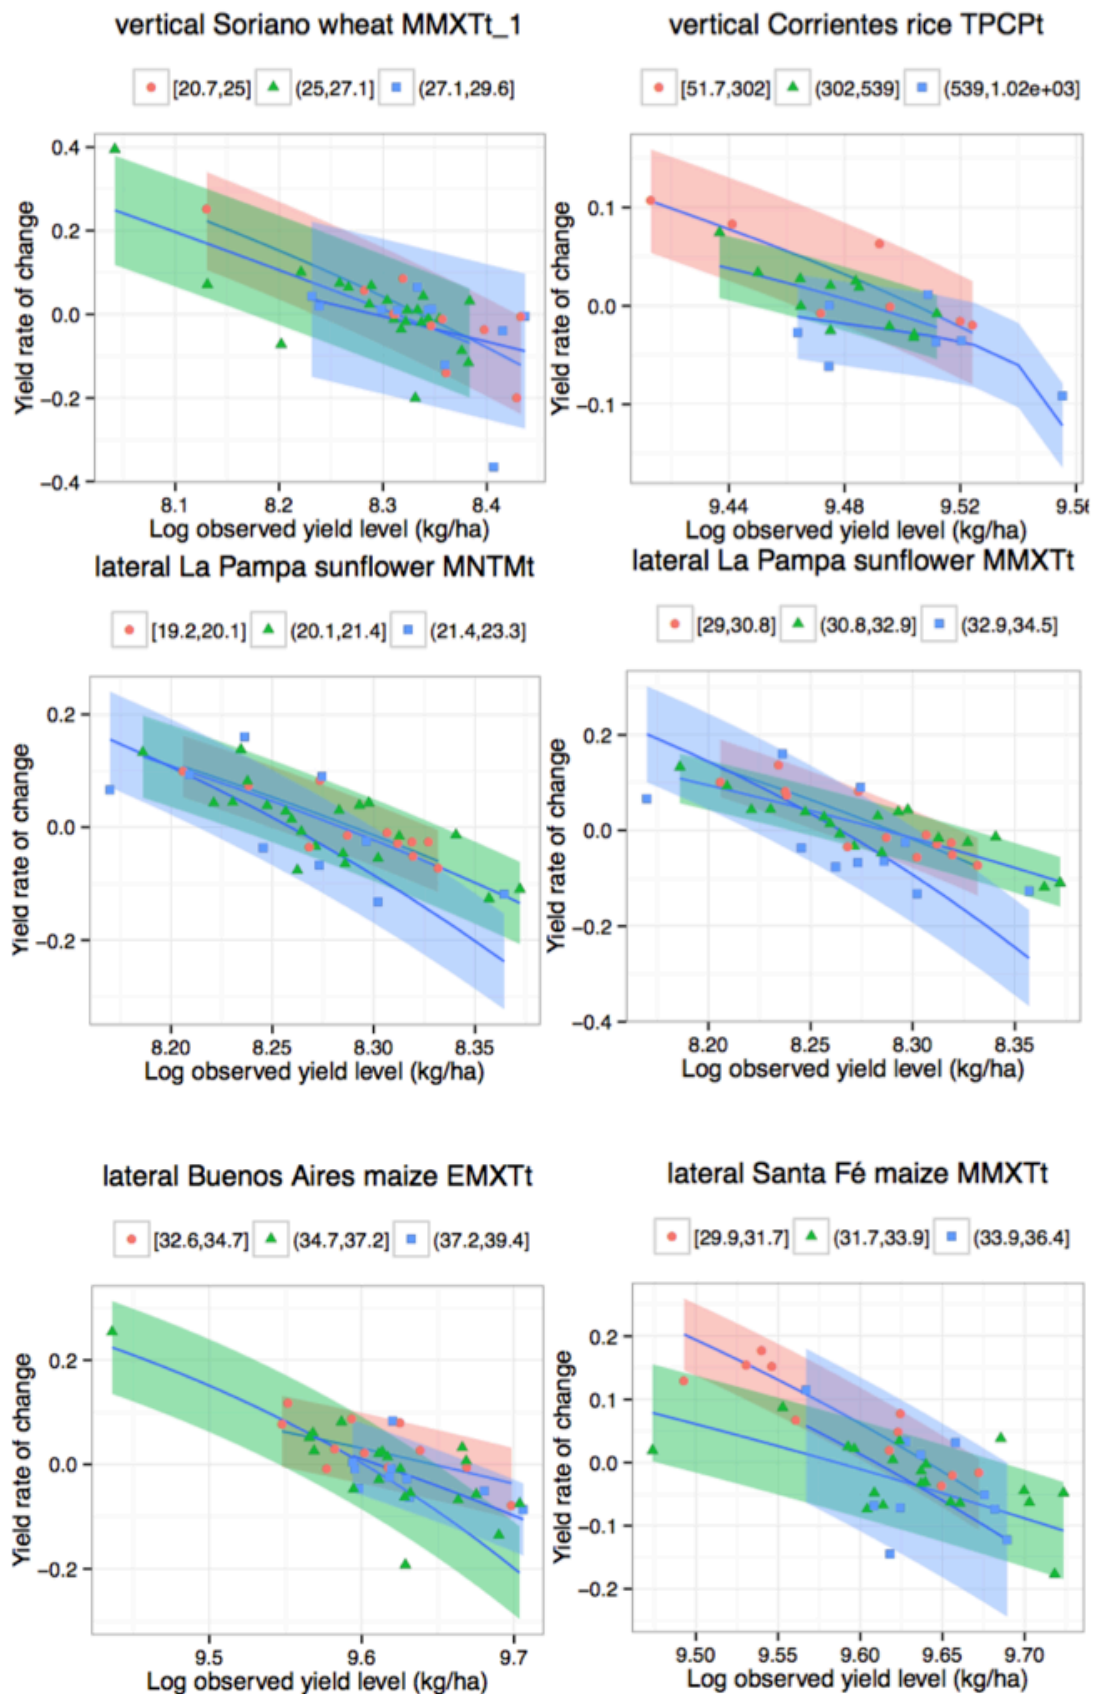
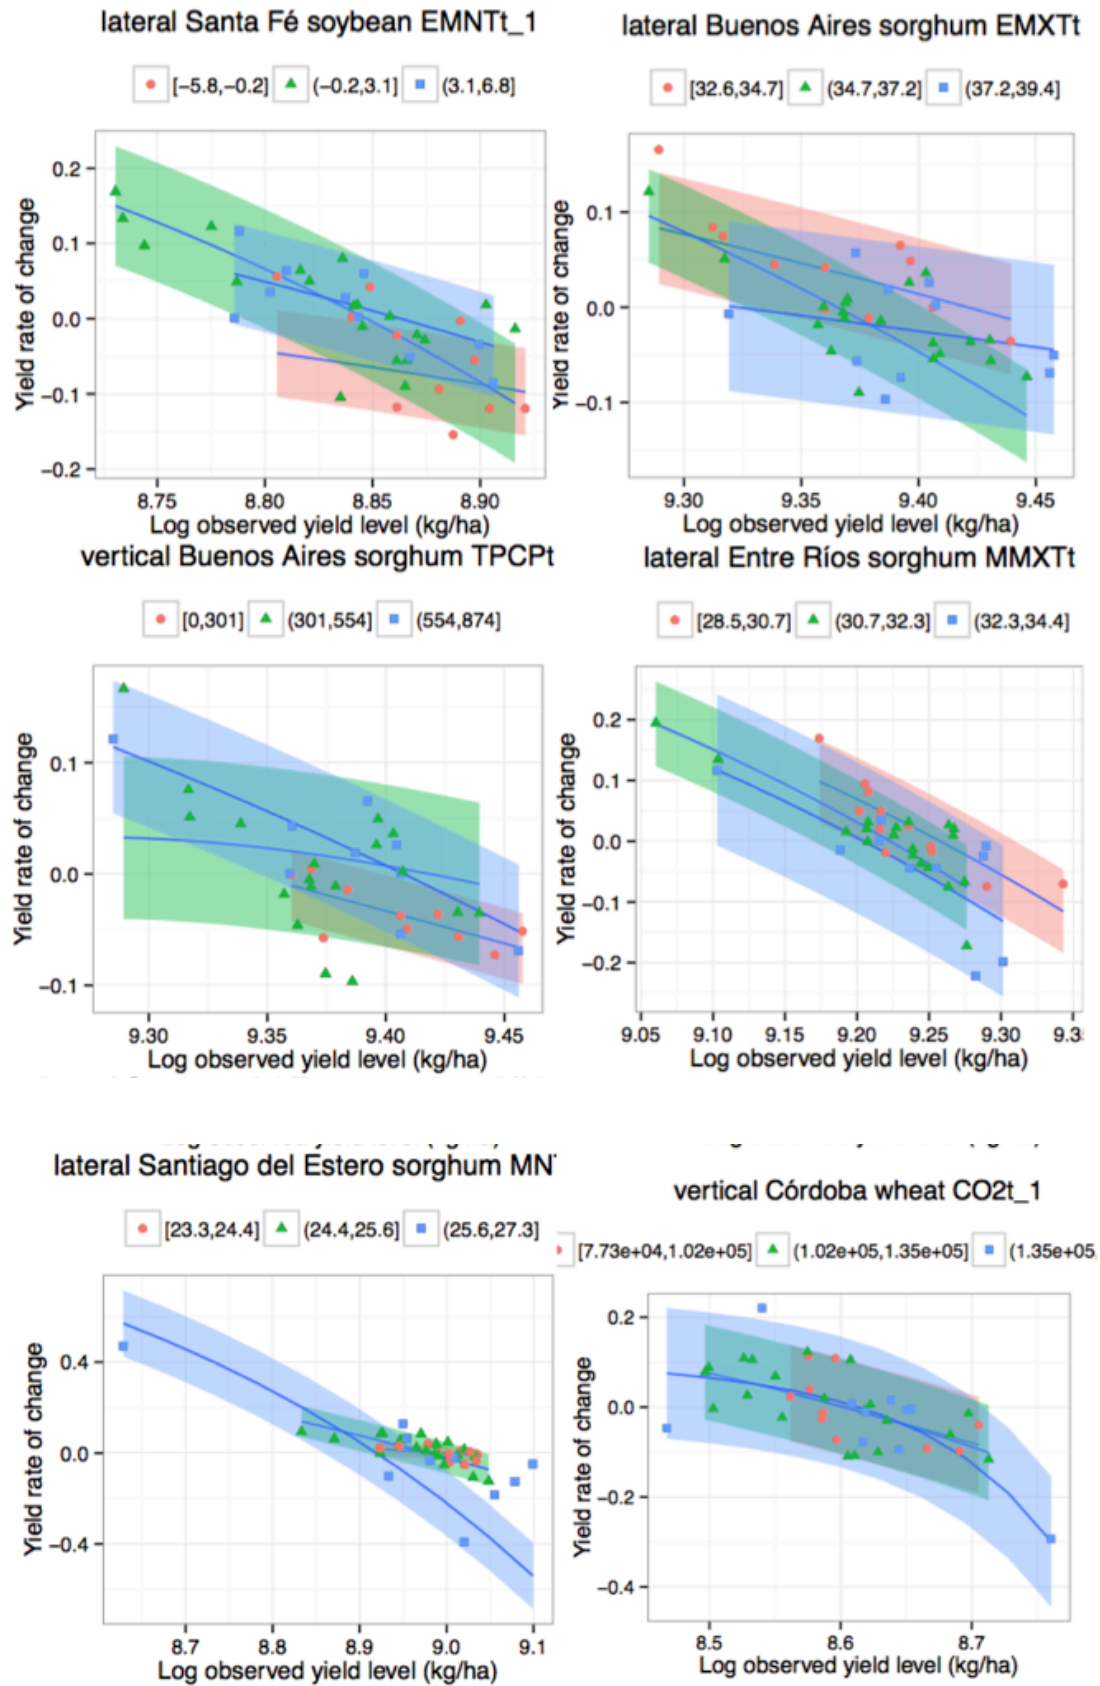








FIGURE S2. Partial Rate Correlation Function (*PRCF*).

























FIGURE S3. Annual crop yield growth rates for crops in several regions of South America for variations in temperature, precipitation and carbon dioxide emissions¹. We showed that these external factors could change the maximum observed year-to-year variation in crop yield r_{\max} (vertical effects), or the parameters c (lateral effects) and a (nonlinear effects). We divided each plot according to quartiles of the external factor behavior (different colors), where shaded area shows confidence bands. See Appendix S1 Table S1 for description of models and Appendix S2 Text S1 for model's description.

¹ Note: CO_2 annual carbon dioxide emission (kt, country-level emissions), and summary statistics of the growing season weather: *EMNT* extreme minimum temperature (°C), *EMXT* extreme maximum temperature (°C), *MMNT* mean minimum temperature (°C), *MMXT* mean maximum temperature (°C), *MNTM* mean temperature (°C), *EMXP* extreme maximum daily precipitation total (l/m2), *TPCP* total precipitation (l/m2).

Appendix S2

TEXT S1. Changes in r_{\max} (I) and c (II) translate the conditional function curve $R_t = f(Y_{t-d}, Z)$

moving it vertically and laterally, respectively, but do not influence its relative shape.


However, perturbations in a (III) influence the relative shape of the conditional production

curve. Perturbations in the parameters r_{\max} and a cause changes in the pattern of oscillation

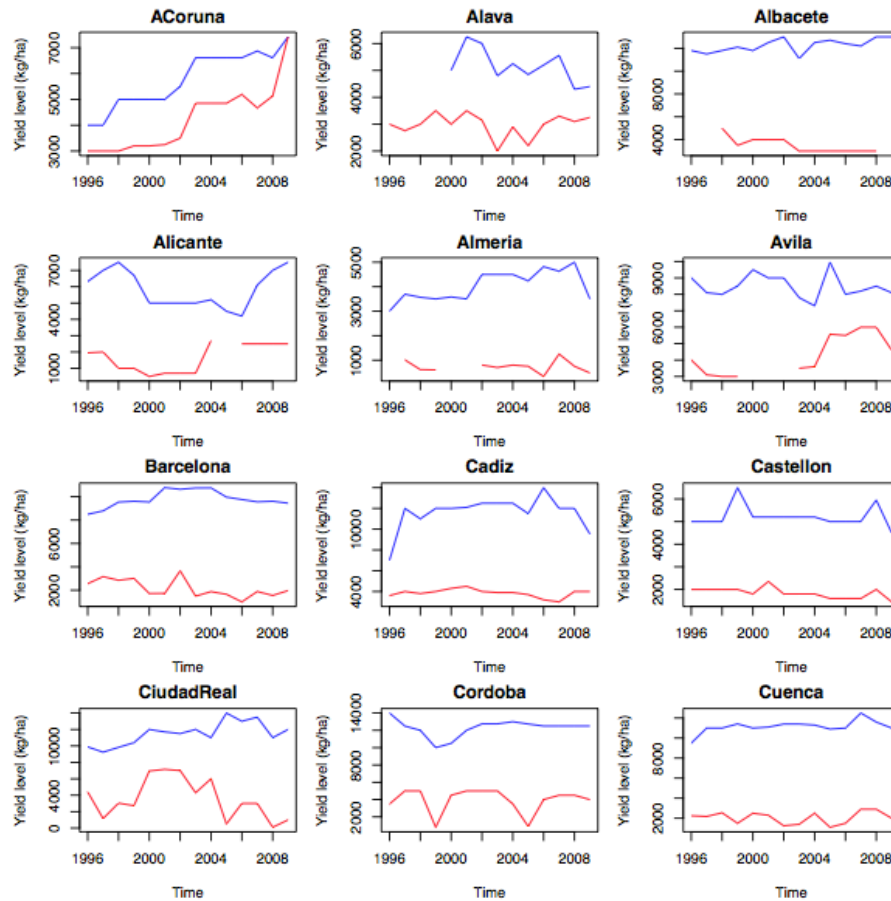
around equilibrium, but c perturbations do not. The stability of the equilibrium point (its

yield potential) is determined by the slope of the function in the vicinity of equilibrium

($r_{\max} * a$): the steeper the slope, the less stable the equilibrium.



SI2. Spatio-Temporal Dynamics of Maize Yield Water Constraints under Climate Change in Spain



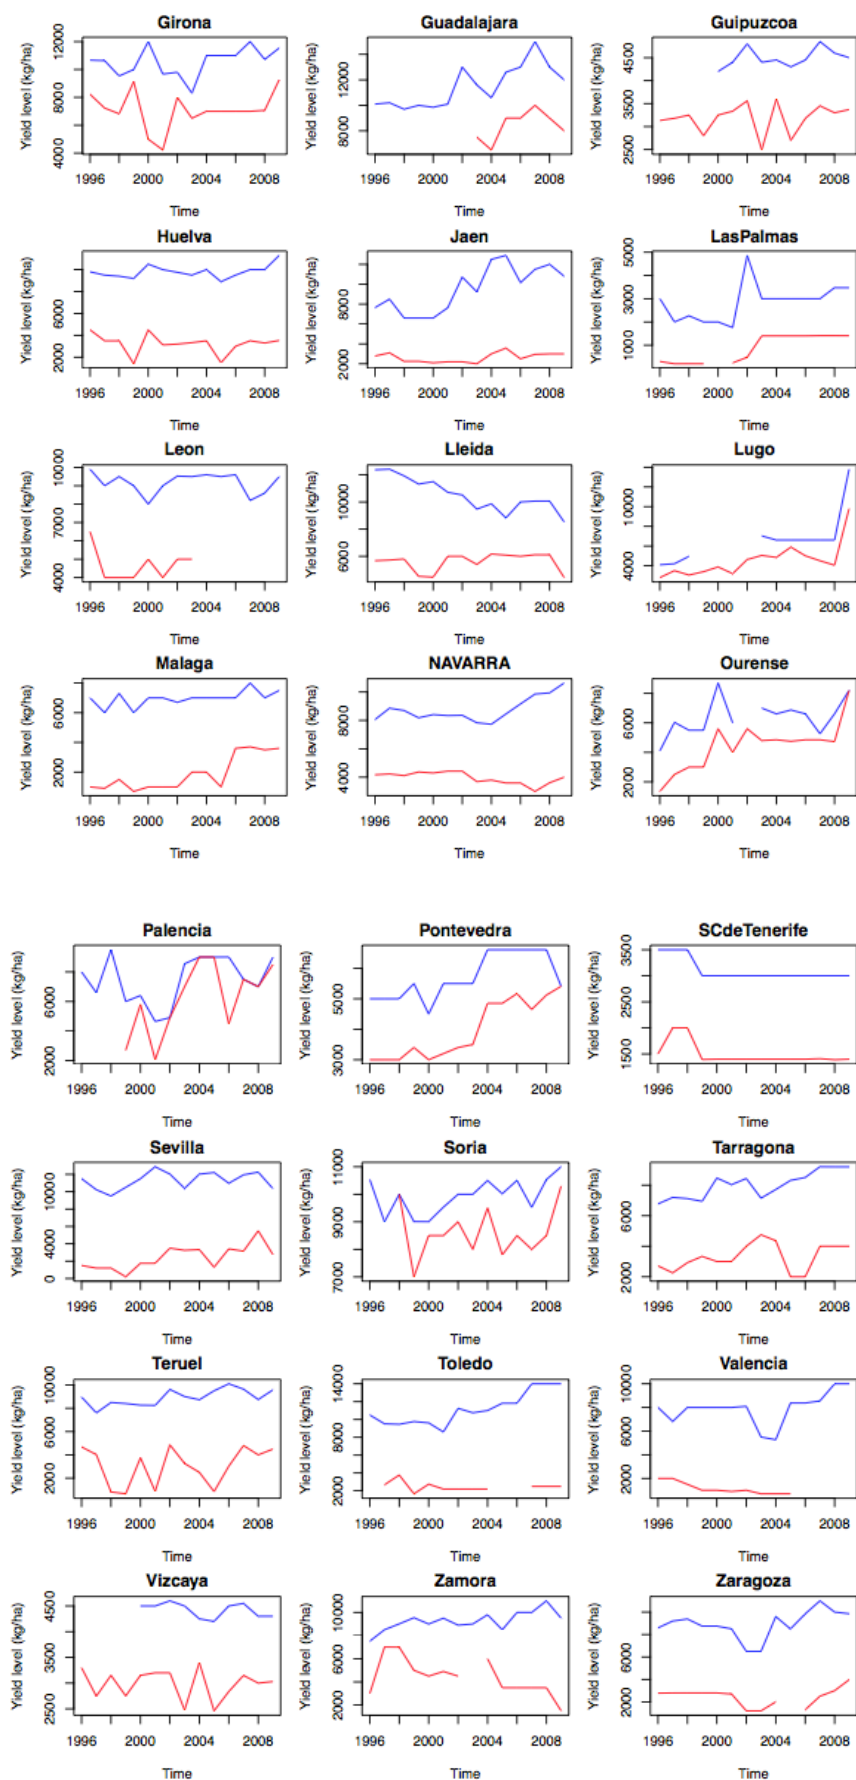
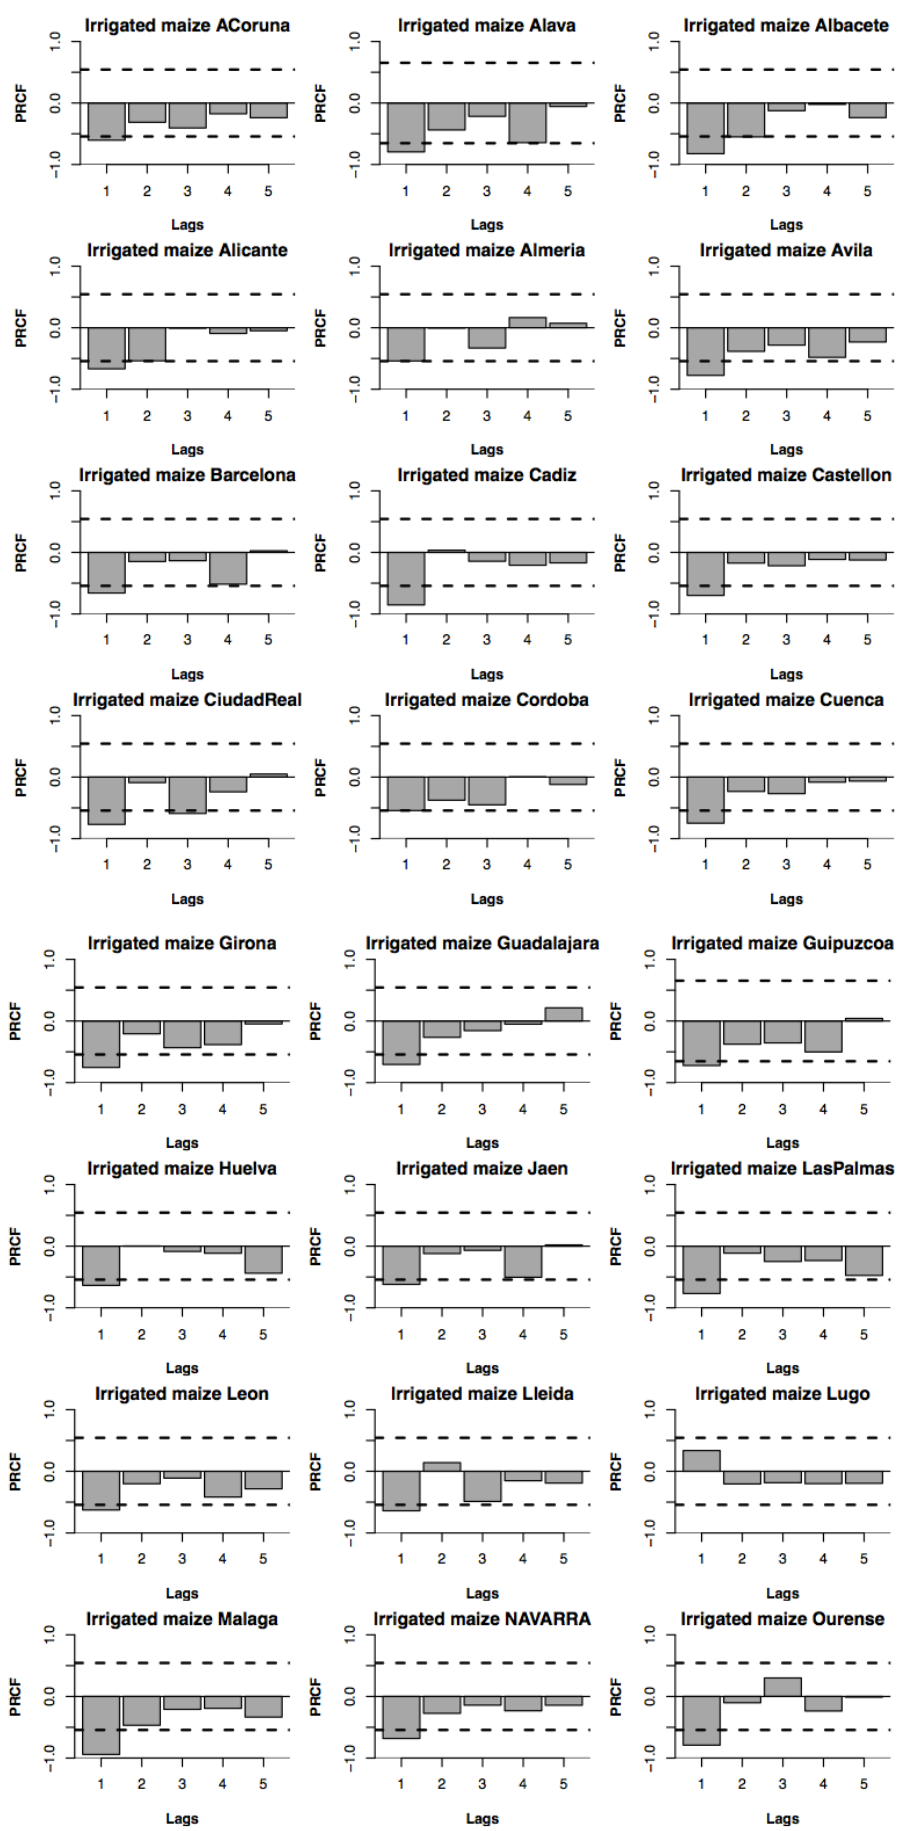
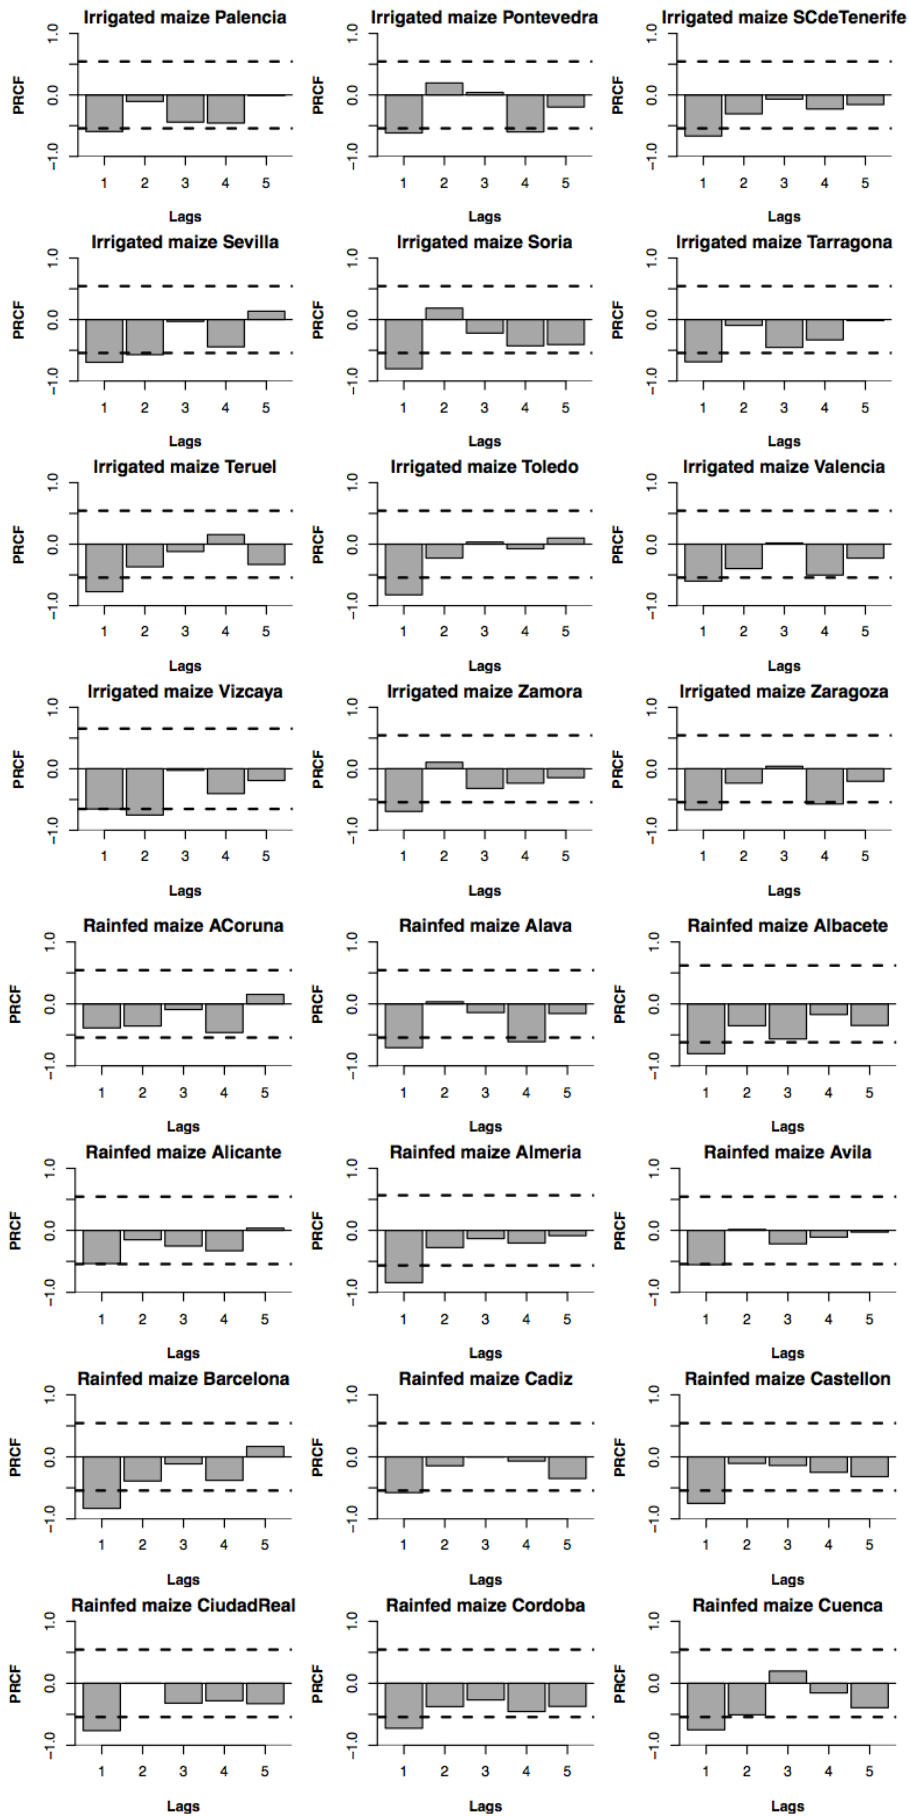


Figure S1. Time series of maize yield level for rainfed and irrigated systems. Each provinces of Spain were analyzed for 1996-2009.





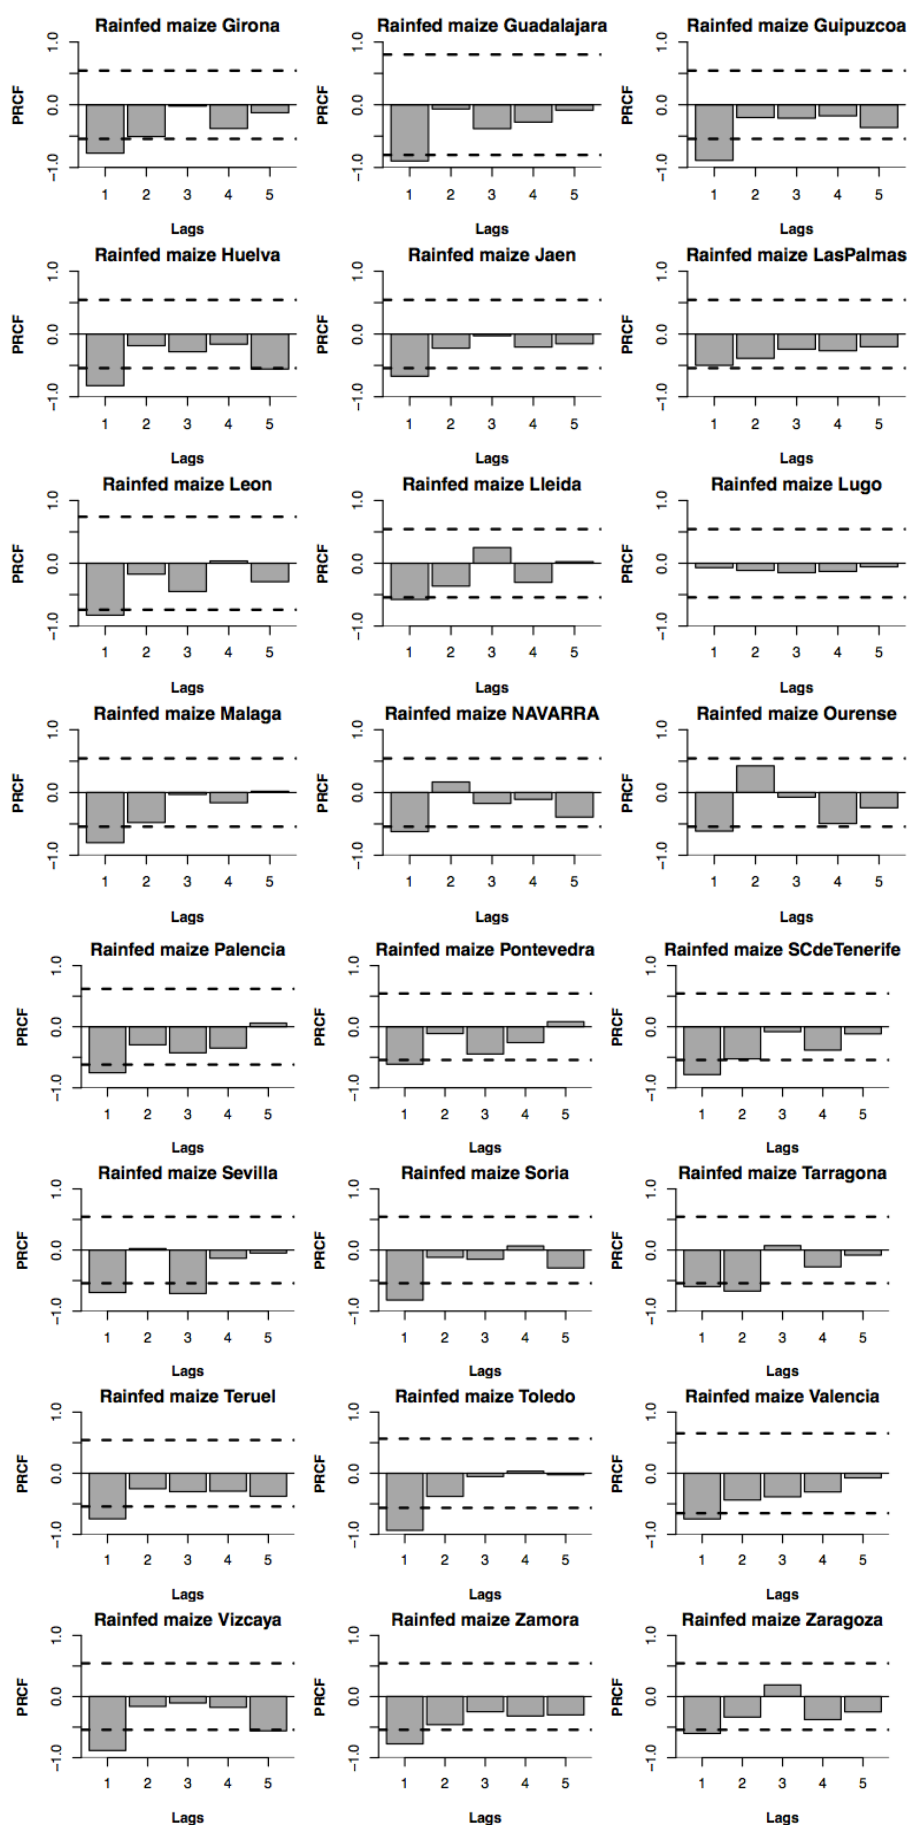


Figure S2. Partial rate correlation function (*PRCF*).

Table S1. Optimal yield dynamics models for Southern South America. Endogenous models represent pure denso-dependence effects, while lateral, vertical and nonlinear models represent the effect of exogenous perturbations. *%Total* percentage of total crop production in Southern South America, *rmax* maximum finite reproductive rate, *a* non-linearity coefficient, *c* equilibrium point, *b* coefficients for different exogenous effects, *R*² pseudo-coefficient of determination and *AIC* Akaike information criterion. Note: *EMNT* extreme minimum temperature (°C), *EMXT* extreme maximum temperature (°C), *MMNT* mean minimum temperature (°C), *MMXT* mean maximum temperature (°C), *MNTM* mean temperature (°C), *EMXP* extreme maximum daily precipitation total (l/m2), *TPCP* total precipitation (l/m2).


<i>%Tot</i>	<i>Sitio</i>	<i>fit</i>	<i>Title</i>	<i>clima</i>	<i>N</i>	<i>NNAs</i>	<i>rmax</i>	<i>logLIK</i>	<i>R2</i>	<i>AIC</i>	<i>AICc</i>	<i>RMSE</i>	<i>a</i>	<i>b</i>	<i>c</i>
14,78	León	vert	irrigated	MMXTi	14,00	1,00	0,12	38,11	0,75	-68,23	-65,83	0,01	0,13*	1,50**	0,69
14,78	León	lat	irrigated	MMXTi	14,00	1,00	0,12	38,07	0,75	-68,13	-65,73	0,01	7,88**	-12,07**	-24,20
14,78	León	endog	irrigated		14,00	1,00	0,12	32,76	0,44	-59,53	-58,44	0,02	7,63*		-80,09*
14,78	León	endog	rainfed		14,00	7,00	0,22	13,74	0,75	-21,48	-20,38	0,03	5,93*		-58,14*
9,44	Huesca	endog	irrigated		14,00	1,00	0,16	37,26	0,79	-68,52	-67,43	0,01	10,22**		-107,07**
6,53	Lleida	endog	irrigated		14,00	1,00	0,13	35,34	0,50	-64,68	-63,59	0,02	8,88*		-94,16*
6,53	Lleida	endog	rainfed		14,00	1,00	0,30	24,42	0,35	-42,85	-41,75	0,04	2,95*		-29,88*
6,32	Zaragoza	endog	irrigated		14,00	1,00	0,39	24,88	0,42	-43,75	-42,66	0,04	2,27*		-24,09*
6,32	Zaragoza	lat	rainfed	TPCPt	14,00	1,00	0,65	20,23	0,64	-32,46	-30,06	0,05	0,66	0,38*	-8,36*
6,32	Zaragoza	endog	rainfed		14,00	1,00	0,65	16,27	0,33	-26,53	-25,44	0,07	1,01*		-9,41*
5,10	Albacete	lat	irrigated	EMNTi	14,00	1,00	0,12	42,84	0,81	-77,69	-75,29	0,01	11,80**	-2,62*	-113,99**
5,10	Albacete	endog	irrigated		14,00	1,00	0,12	40,07	0,71	-74,14	-73,04	0,01	12,54**		-133,90**
5,10	Albacete	lat	rainfed	EMNTi_1	14,00	4,00	0,13	25,47	0,86	-42,94	-40,54	0,02	10,70**	-8,81*	-60,19*
5,10	Albacete	endog	rainfed		14,00	4,00	0,13	21,34	0,69	-36,68	-35,59	0,03	10,30**		-97,45**
5,06	Zamora	endog	irrigated		14,00	1,00	0,16	32,76	0,61	-59,52	-58,43	0,02	7,57**		-79,30**
5,06	Zamora	endog	rainfed		14,00	1,00	0,85	16,23	0,59	-26,45	-25,36	0,07	1,22**		-11,76**
4,32	Sevilla	lat	irrigated	EMXTi_1	14,00	1,00	0,15	32,79	0,69	-57,59	-55,19	0,02	5,44*	-9,41*	-12,07
4,32	Sevilla	endog	irrigated		14,00	1,00	0,15	29,96	0,52	-53,93	-52,84	0,02	6,80*		-72,87*
4,32	Sevilla	lat	rainfed	EMNTi	14,00	1,00	2,16	13,12	0,82	-18,23	-15,83	0,09	0,60**	2,39*	-15,79**
4,32	Sevilla	endog	rainfed		14,00	1,00	2,16	8,00	0,60	-10,00	-8,91	0,13	0,58**		-4,42*
4,27	Toledo	endog	irrigated		14,00	1,00	0,27	33,72	0,63	-61,45	-60,35	0,02	4,77**		-51,02**
4,27	Toledo	endog	rainfed		14,00	2,00	0,50	24,31	0,91	-42,61	-41,52	0,03	3,50**		-31,87**
3,43	Navarra	vert	irrigated	EMXPt_1	14,00	1,00	0,09	42,85	0,71	-77,70	-75,30	0,01	1,90*	0,07*	-20,20*
3,43	Navarra	lat	irrigated	EMXPt_1	14,00	1,00	0,09	42,36	0,69	-76,72	-74,32	0,01	8,79**	-0,73*	-88,23**
3,43	Navarra	endog	irrigated		14,00	1,00	0,09	38,76	0,46	-71,52	-70,43	0,01	8,56*		-89,46*

%Tot	Sitio	fit	Title	clima	N	NNAs	rmax	logLIK	R2	AIC	AICc	RMSE	a	b	c
14,78	León	vert	irrigated	MMXTt	14,00	1,00	0,12	38,11	0,75	-68,23	-65,83	0,01	0,13*	1,50**	0,69
14,78	León	lat	irrigated	MMXTt	14,00	1,00	0,12	38,07	0,75	-68,13	-65,73	0,01	7,88**	-12,07**	-24,20
14,78	León	endog	irrigated		14,00	1,00	0,12	32,76	0,44	-59,53	-58,44	0,02	7,63*		-80,09*
14,78	León	endog	rainfed		14,00	7,00	0,22	13,74	0,75	-21,48	-20,38	0,03	5,93*		-58,14*
3,43	Navarra	lat	rainfed	MMNTt_1	14,00	1,00	0,18	32,26	0,54	-56,53	-54,13	0,02	3,81*	6,61*	-68,45*
2,32	Girona	lat	irrigated	MMXTt_1	14,00	1,00	0,28	31,15	0,73	-54,29	-51,89	0,02	3,74**	-4,70*	-17,17
2,32	Girona	vert	irrigated	MNTMt_1	14,00	1,00	0,28	30,79	0,71	-53,59	-51,19	0,02	0,09	2,41*	1,56
2,32	Girona	endog	irrigated		14,00	1,00	0,28	28,06	0,56	-50,13	-49,04	0,03	4,00**		-42,74**
2,32	Girona	endog	rainfed		14,00	1,00	0,64	19,97	0,62	-33,94	-32,85	0,05	1,96**		-19,95**
1,93	Córdoba	lat	irrigated	MMNTt_1	14,00	1,00	0,13	35,94	0,55	-63,88	-61,48	0,02	3,04	-7,02*	-0,74
1,93	Córdoba	lat	rainfed	TPCPt	14,00	1,00	1,73	10,45	0,68	-12,90	-10,50	0,11	0,62**	0,15*	-6,06**
1,93	Córdoba	lat	rainfed	EMXPt	14,00	1,00	1,73	10,90	0,70	-13,81	-11,41	0,10	0,66**	0,37*	-7,47**
1,93	Córdoba	endog	rainfed		14,00	1,00	1,73	7,86	0,52	-9,73	-8,64	0,13	0,64*		-5,48*
1,75	Ciudad Real	vert	irrigated	EMNTt_1	14,00	1,00	0,24	33,72	0,77	-59,44	-57,04	0,02	0,35*	0,79*	-2,29
1,75	Ciudad Real	lat	irrigated	EMNTt_1	14,00	1,00	0,24	33,19	0,75	-58,37	-55,97	0,02	5,41**	-3,37*	-42,28**
1,75	Ciudad Real	endog	irrigated		14,00	1,00	0,24	30,03	0,59	-54,06	-52,97	0,02	4,71**		-50,63**
1,75	Ciudad Real	endog	rainfed		14,00	1,00	2,29	4,83	0,59	-3,66	-2,57	0,17	0,52**		-3,94*
1,43	Guadalajara	endog	irrigated		14,00	1,00	0,25	27,24	0,43	-48,49	-47,40	0,03	3,56*		-38,57*
1,43	Guadalajara	endog	rainfed		14,00	8,00	0,33	14,77	0,82	-23,54	-22,45	0,02	4,99*		-51,68*
1,38	A Coruña	endog	irrigated		14,00	1,00	0,22	33,34	0,44	-60,69	-59,60	0,02	3,97*		-40,20*
1,38	A Coruña	endog	rainfed		14,00	1,00	0,37	23,11	0,36	-40,22	-39,13	0,04	2,40*		-23,70*
1,13	Teruel	vert	irrigated	MMNTt_1	14,00	1,00	0,15	37,30	0,77	-66,60	-64,20	0,01	0,26	0,83*	-1,20
1,13	Teruel	lat	irrigated	MMNTt_1	14,00	1,00	0,15	37,07	0,76	-66,13	-63,73	0,01	6,58**	-4,96*	-45,79*
1,13	Teruel	vert	irrigated	MNTMt_1	14,00	1,00	0,15	37,36	0,77	-66,72	-64,32	0,01	0,08	2,45*	1,66
1,13	Teruel	endog	irrigated		14,00	1,00	0,15	34,08	0,62	-62,16	-61,07	0,02	7,28**		-76,06**
1,13	Teruel	vert	rainfed	TPCPt_1	14,00	1,00	1,74	8,92	0,72	-9,84	-7,44	0,12	0,26**	0,63*	-0,71
1,13	Teruel	lat	rainfed	TPCPt_1	14,00	1,00	1,74	8,94	0,72	-9,88	-7,48	0,12	0,79**	-0,37*	-4,64*
1,13	Teruel	vert	rainfed	EMXPt	14,00	1,00	1,74	8,88	0,72	-9,76	-7,36	0,12	0,11	1,29*	1,12
1,13	Teruel	lat	rainfed	EMXPt	14,00	1,00	1,74	9,27	0,74	-10,55	-8,15	0,12	0,49*	-0,84*	0,16
1,13	Teruel	endog	rainfed		14,00	1,00	1,74	5,73	0,55	-5,46	-4,37	0,16	0,62**		-5,12*
1,00	Palencia	endog	irrigated		14,00	1,00	0,55	17,25	0,39	-28,49	-27,40	0,06	1,40*		-14,61*
1,00	Palencia	endog	rainfed		14,00	4,00	0,86	9,53	0,59	-13,07	-11,98	0,09	1,45*		-14,37*
0,94	Cádiz	endog	irrigated		14,00	1,00	0,54	29,61	0,71	-53,23	-52,14	0,02	2,40**		-25,77**
0,94	Cádiz	lat	rainfed	MMNTt_1	14,00	1,00	0,29	31,00	0,57	-54,01	-51,61	0,02	2,00*	5,27*	-44,94*
0,94	Cádiz	lat	rainfed	MNTMt_1	14,00	1,00	0,29	31,82	0,62	-55,63	-53,23	0,02	2,90*	14,53*	-98,35*
0,94	Cádiz	lat	rainfed	EMXTt	14,00	1,00	0,29	30,33	0,52	-52,66	-50,26	0,02	1,95	4,09*	-39,70*
0,89	Pontevedra	endog	irrigated		14,00	1,00	0,20	27,60	0,34	-49,21	-48,12	0,03	4,20*		-42,51*
0,89	Pontevedra	endog	rainfed		14,00	1,00	0,33	27,74	0,36	-49,48	-48,39	0,03	2,17*		-21,47*
0,37	Cuenca	endog	irrigated		14,00	1,00	0,15	37,91	0,54	-69,81	-68,72	0,01	6,73**		-72,00**
0,37	Cuenca	endog	rainfed		14,00	1,00	0,66	13,35	0,61	-20,69	-19,60	0,09	1,91**		-17,12**
0,35	Ourense	lat	irrigated	MNTMt_1	14,00	1,00	0,46	24,36	0,75	-40,73	-38,33	0,04	2,87**	12,02*	-86,68**
0,35	Ourense	endog	irrigated		14,00	1,00	0,46	21,11	0,58	-36,22	-35,12	0,05	2,52**		-25,61**
0,35	Ourense	vert	rainfed	CO2t	14,00	1,00	0,62	18,23	0,72	-28,46	-26,06	0,05	12,72	-0,05**	-124,07
0,35	Ourense	endog	rainfed		14,00	1,00	0,62	15,95	0,46	-25,90	-24,81	0,07	1,75*		-17,09*
0,31	Jaén	endog	irrigated		14,00	1,00	0,34	21,36	0,38	-36,73	-35,64	0,05	2,20*		-23,62*


%Tot	Sitio	fit	Title	clima	N	NNAs	rmax	logLIK	R2	AIC	AICc	RMSE	a	b	c
14,78	León	vert	irrigated	MMXTt	14,00	1,00	0,12	38,11	0,75	-68,23	-65,83	0,01	0,13*	1,50**	0,69
14,78	León	lat	irrigated		14,00	1,00	0,12	38,07	0,75	-68,13	-65,73	0,01	7,88**	-12,07**	-24,20
14,78	León	endog	irrigated		14,00	1,00	0,12	32,76	0,44	-59,53	-58,44	0,02	7,63*		-80,09*
14,78	León	endog	rainfed		14,00	7,00	0,22	13,74	0,75	-21,48	-20,38	0,03	5,93*		-58,14*
0,31	Jaén	endog	rainfed		14,00	1,00	0,41	21,05	0,44	-36,10	-35,01	0,05	2,09*		-19,68*
0,29	Lugo	lat	irrigated	CO2t	14,00	1,00	0,74	36,24	0,98	-64,47	-62,07	0,01	-0,18	0,28**	-2,04
0,29	Lugo	endog	rainfed		14,00	1,00	0,88	13,15	0,45	-20,29	-19,20	0,09	1,38*		-13,26*
0,23	Barcelona	endog	irrigated		14,00	1,00	0,12	40,44	0,39	-74,87	-73,78	0,01	6,86*		-72,72*
0,23	Barcelona	endog	rainfed		14,00	1,00	0,75	14,20	0,68	-22,39	-21,30	0,08	1,69**		-15,12**
0,20	Ávila	endog	irrigated	CO2t	14,00	1,00	0,31	28,54	0,59	-51,08	-49,99	0,03	3,68**		-38,51**
0,20	Ávila	vert	rainfed		14,00	1,00	0,44	25,39	0,78	-42,78	-40,38	0,03	0,18*	0,25*	-0,43
0,20	Ávila	lat	rainfed		14,00	1,00	0,44	25,13	0,77	-42,25	-39,85	0,03	1,42*	-0,53*	-7,56
0,13	Soria	endog	irrigated	TPCPl_1 EMXPl_1 EMXPl_1 CO2t_1	14,00	1,00	0,11	36,61	0,67	-67,22	-66,12	0,01	11,91**		-124,91**
0,13	Soria	lat	rainfed		14,00	1,00	0,19	32,14	0,84	-56,28	-53,88	0,02	7,98**	-0,37*	-80,76**
0,13	Soria	vert	rainfed		14,00	1,00	0,19	31,27	0,81	-54,54	-52,14	0,02	1,00*	0,25*	-9,82*
0,13	Soria	lat	rainfed		14,00	1,00	0,19	32,40	0,84	-56,80	-54,40	0,02	7,17**	-1,21*	-68,69**
0,13	Soria	vert	rainfed		14,00	1,00	0,19	31,03	0,80	-54,06	-51,66	0,02	31,87	-0,01**	-327,41
0,13	Soria	endog	rainfed		14,00	1,00	0,19	28,94	0,73	-51,88	-50,79	0,03	7,82**		-81,21**
0,11	Málaga	endog	irrigated	EMNTt_1	14,00	1,00	0,20	38,14	0,88	-70,28	-69,19	0,01	8,75**		-88,68**
0,11	Málaga	vert	rainfed		14,00	1,00	1,28	16,05	0,79	-24,10	-21,70	0,07	0,07*	3,45*	2,23**
0,11	Málaga	lat	rainfed		14,00	1,00	1,28	15,61	0,78	-23,21	-20,81	0,07	1,01**	-2,80*	4,67
0,11	Málaga	endog	rainfed		14,00	1,00	1,28	11,47	0,58	-16,93	-15,84	0,10	0,95**		-7,93**
0,11	Valencia	endog	irrigated		14,00	1,00	0,46	22,77	0,38	-39,55	-38,45	0,04	1,69*		-17,77*
0,11	Valencia	endog	rainfed		14,00	5,00	0,11	16,37	0,54	-26,74	-25,65	0,04	9,61*		-80,63*
0,05	Huelva	endog	irrigated		14,00	1,00	0,13	34,55	0,39	-63,10	-62,00	0,02	6,60*		-69,92*
0,05	Huelva	endog	rainfed		14,00	1,00	1,17	13,82	0,66	-21,63	-20,54	0,08	1,18**		-10,64**
0,04	Alicante	endog	irrigated		14,00	1,00	0,37	25,24	0,44	-44,47	-43,38	0,03	2,03*		-20,86*
0,03	Guipuzcoa	endog	irrigated		14,00	5,00	0,09	26,29	0,54	-46,57	-45,48	0,01	11,43*		-111,11*
0,03	Guipuzcoa	endog	rainfed		14,00	1,00	0,37	29,32	0,81	-52,65	-51,56	0,03	4,62**		-43,38**
0,02	Las Palmas	endog	irrigated		14,00	1,00	1,02	14,94	0,56	-23,87	-22,78	0,08	0,99**		-8,93**
0,02	S.C. de Tenerife	endog	rainfed		14,00	1,00	0,29	26,38	0,59	-46,76	-45,66	0,03	3,46**		-30,35**
0,02	Tarragona	endog	irrigated		14,00	1,00	0,20	33,02	0,48	-60,03	-58,94	0,02	4,82*		-50,30*
0,02	Tarragona	endog	rainfed		14,00	1,00	0,69	14,14	0,35	-22,28	-21,18	0,08	1,08*		-10,28*
0,01	Castellón	endog	irrigated		14,00	1,00	0,26	28,08	0,62	-50,17	-49,07	0,03	4,31**		-42,97**
0,01	Castellón	endog	rainfed		14,00	1,00	0,27	26,90	0,65	-47,81	-46,72	0,03	4,46**		-39,73**
0,01	Vizcaya	endog	rainfed		14,00	1,00	0,32	29,25	0,80	-52,50	-51,41	0,03	5,10**		-47,61**
0,00	Álava	endog	irrigated	MMXTt	14,00	5,00	0,22	19,03	0,63	-32,07	-30,98	0,03	5,33*		-52,96*
0,00	Álava	lat	rainfed		14,00	1,00	0,37	24,38	0,69	-40,75	-38,35	0,04	3,27**	6,14*	-60,51**
0,00	Álava	endog	rainfed		14,00	1,00	0,37	21,14	0,49	-36,28	-35,19	0,05	2,74*		-25,88*
0,00	Almería	lat	irrigated	EMNTt	14,00	1,00	0,25	31,87	0,78	-55,74	-53,34	0,02	5,57**	8,18**	-92,44**
0,00	Almería	endog	irrigated		14,00	1,00	0,25	26,15	0,48	-46,30	-45,21	0,03	4,73*		-45,90*
0,00	Almería	lat	rainfed		14,00	2,00	1,32	14,96	0,81	-21,93	-19,53	0,07	1,08**	3,98*	-26,79*
0,00	Almería	endog	rainfed		14,00	2,00	1,32	11,27	0,65	-16,54	-15,45	0,09	0,95**		-7,00**

NOTE: * $p < 0.05$, ** $p < 0.01$


vertical Teruel irrigated MMNT1_1




lateral Teruel irrigated MMNT1_1




lateral Córdoba irrigated MMNT1_1




lateral Navarra rainfed MMNT1_1




lateral Cádiz rainfed MMNT1_1




lateral Albacete irrigated EMNT1




lateral Almería irrigated EMNT1




lateral C.Real irrigated EMNT1_1




vertical C.Real irrigated EMNTl_1




lateral Sevilla rainfed EMNTl




lateral Almería rainfed EMNTl




lateral Málaga rainfed EMNTl_1




vertical Málaga rainfed EMNTl_1




lateral Albacete rainfed EMNTl_1




vertical León irrigated MMXTl




lateral León irrigated MMXTl




lateral Girona irrigated MMXT1_1




lateral Álava rainfed MMXT1




lateral Sevilla irrigated EMXT1_1




lateral Zaragoza rainfed TPCPt




lateral Cordoba rainfed TPCPt




lateral Soria rainfed TPCPt_1




lateral Teruel rainfed TPCPt_1




lateral Teruel rainfed EMXPT




vertical Teruel rainfed EMXPt




lateral Cordoba rainfed EMXPt




lateral Navarra rainfed EMXPt_1




vertical Navarra rainfed EMXPt_1




vertical Ávila rainfed CO2t




lateral Ávila rainfed CO2t



vertical Ourense rainfed CO2t



vertical Soria rainfed CO2t_1



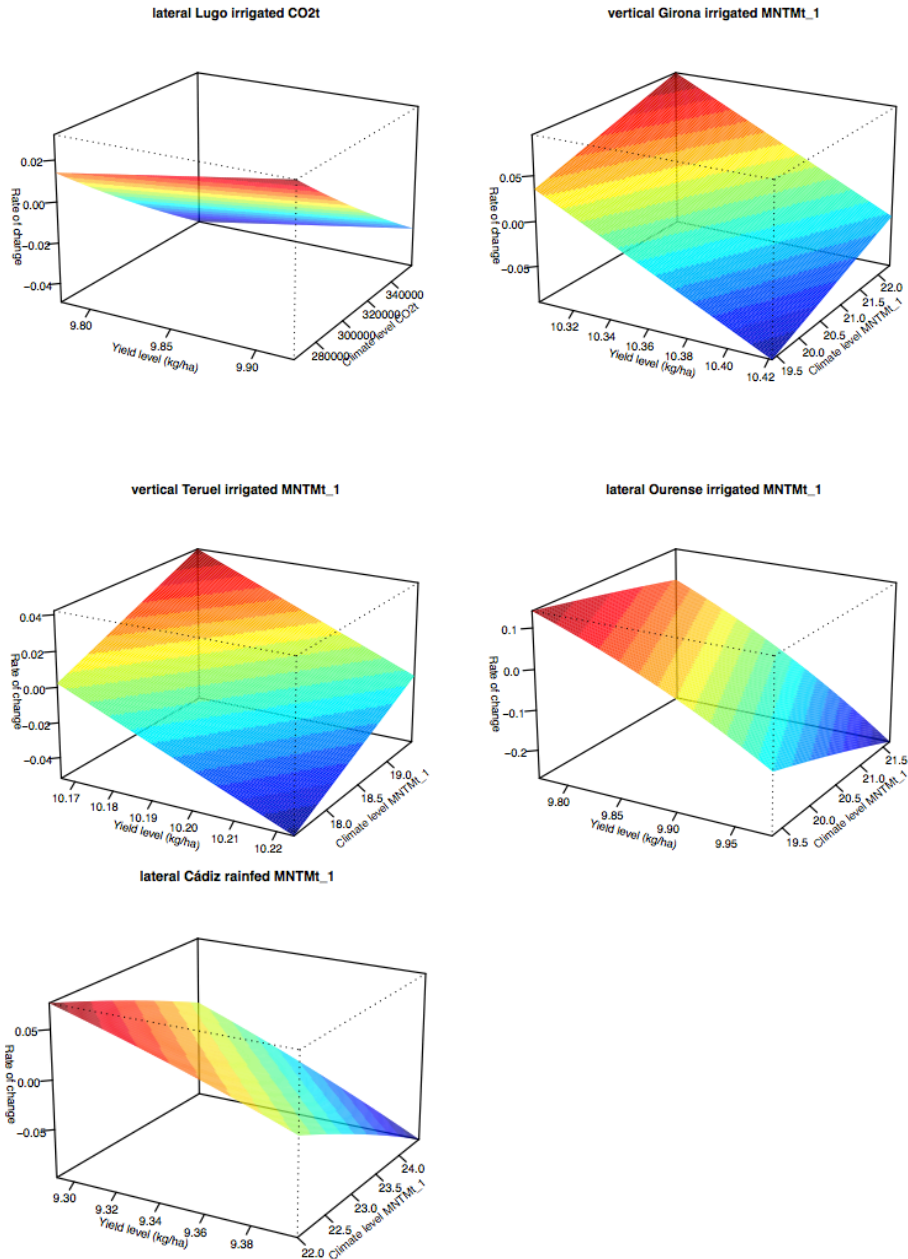


Figure S3. *R*-functions: yield rate of change against the log observed yield level (with one year of delay). Climate factors had vertical (additive) and lateral (non-additive) perturbations on the *R*-function. Colors indicate the value of the *R*-function. See Table S1 for description of models.

Note: *EMNT* extreme minimum temperature (°C), *EMXT* extreme maximum temperature (°C), *MMNT* mean minimum temperature (°C), *MMXT* mean maximum temperature (°C), *MNTM* mean temperature (°C), *EMXP* extreme maximum daily precipitation total (l/m²), *TPCP* total precipitation (l/m²).

SI3. Weed Diversity Affects Soybean and Maize Yield in a Long Term Experiment in Michigan, USA

Table S1. Descriptive statistics for crop yield (kg/ha), precipitation (mm), temperature (degrees C) and weed diversity (based on weed biomass, g/m²) variables for maize (*ZeaL*) and soyabean (*GlycL*) production, 1996–2011. Mean (*pM*) and maximum (*pMax*) precipitation, minimum (*tMin*), maximum (*tMax*) and mean (*tM*) temperature, the average minimum (*tmin*) and maximum (*tmax*) temperature for growing season and weed community diversity indices –*Shannon*, *Simpson*, *Inverse Simpson*, *J* and *E evenness* indices-. See SI Appendix A1 for biodiversity indices explanation.

Variable	<i>GlycL</i> , N=141					<i>ZeaL</i> , N=144				
	Min	Max	M	SD	Md	Min	Max	M	SD	Md
<i>Yield</i>	681.90	3758.30	2277.39	718.19	2250.15	1778.00	12861.50	5990.04	2648.84	5102.65
<i>Shannon</i>	0.00	2.07	0.78	0.46	0.76	0.00	1.93	0.90	0.56	0.92
<i>Simpson</i>	0.00	0.83	0.40	0.23	0.42	0.00	0.84	0.44	0.26	0.48
<i>Invsimpson</i>	1.00	5.90	1.99	0.89	1.72	1.00	6.11	2.25	1.14	1.93
<i>J-evenness</i>	0.04	0.99	0.51	0.21	0.52	0.03	1.00	0.49	0.21	0.51
<i>E-evenness</i>	0.16	1.00	0.52	0.25	0.46	0.10	1.00	0.47	0.25	0.42
<i>pM</i>	2.22	3.31	2.71	0.35	2.82	1.71	4.63	2.90	0.97	2.59
<i>pMax</i>	35.56	69.34	47.19	10.90	46.36	29.57	137.16	63.45	36.10	57.57
<i>tM</i>	16.71	18.65	17.40	0.60	17.25	17.97	19.85	18.99	0.60	19.04
<i>tmax</i>	22.74	25.69	23.68	1.01	22.99	23.71	27.40	25.58	1.09	25.51
<i>tmin</i>	10.93	12.48	11.62	0.56	11.53	11.86	13.54	12.68	0.60	12.65
<i>tMax</i>	32.11	39.49	35.45	2.18	35.32	33.68	38.57	35.67	1.79	35.38
<i>tMin</i>	-3.18	-0.91	-2.39	0.75	-2.88	-4.44	0.72	-1.43	1.84	-1.01

NOTE: Min, minimum; Max, maximum; M, mean; SD, standard deviation; Md, median; N, sample size.

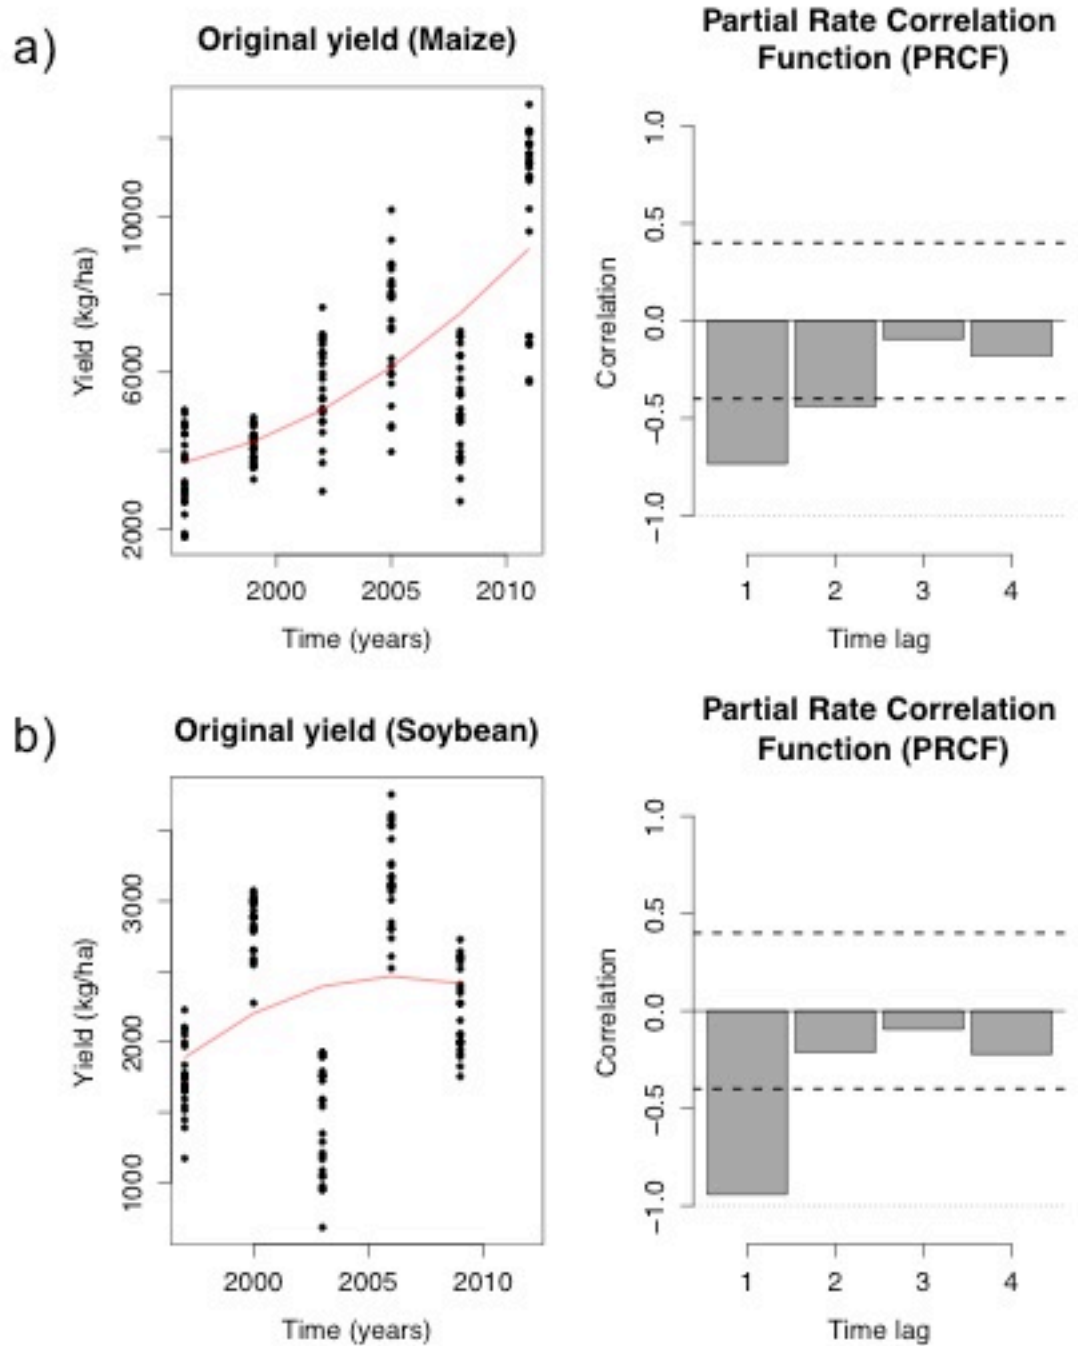


Figure S1. Diagnostic tools for the log-transformed time series of a) maize (*ZeaL*) and b) soyabean (*GlycL*) yield level. Its panels show the original time series and the Partial Rate Correlation Function (*PRCF*). Dotted lines indicate 95% confidence intervals ($2/\sqrt{n}$)

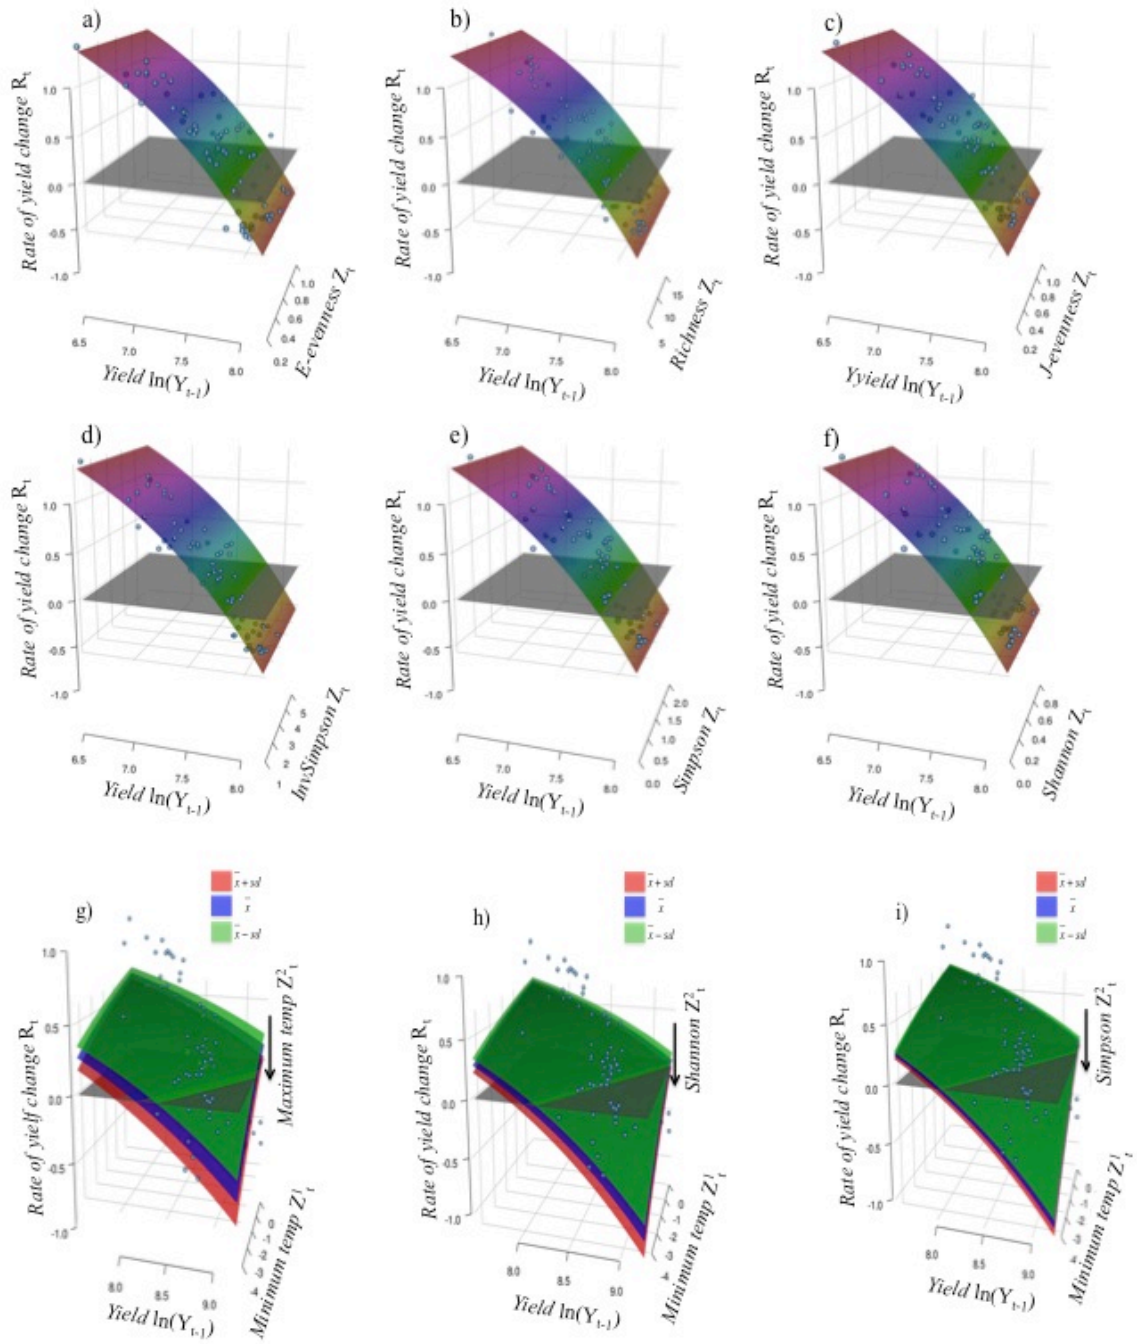


Figure S2. Annual rates of yield increase R_t against the log-yield level Y_{t-1} (with one year of delay) for: soyabean (*GlycL*; additive effects of weed diversity a-f) and maize (*ZeaL*; non-additive interaction effects of minimum temperature with: g) average maximum temperature (t_{max}/t_{Min}), h) weed Shannon diversity index ($\text{Shannon}/t_{Min}$) and i) weed Simpson diversity index ($\text{Simpson}/t_{Min}$) interactions), where the external factor Z_t perturbs the productivity

function. Colours indicate the R^2 values. See Table S1 for description of models and Figure 2 for their graphs.

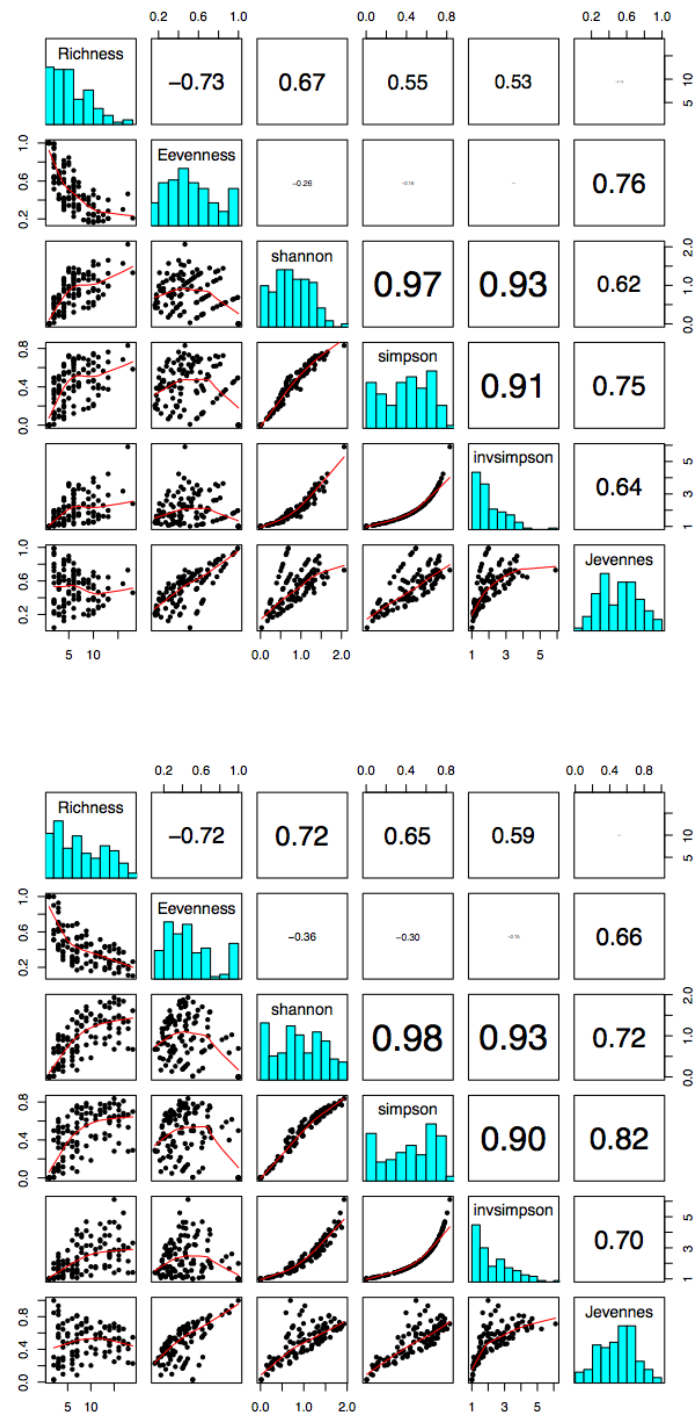
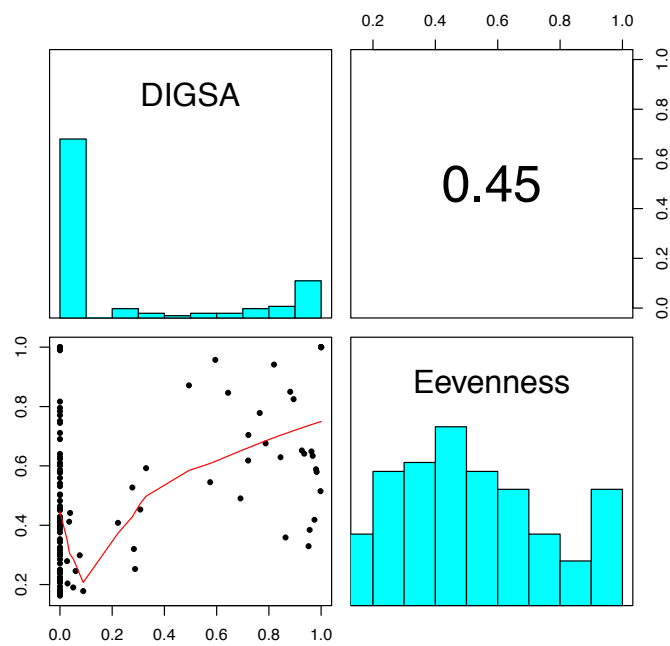
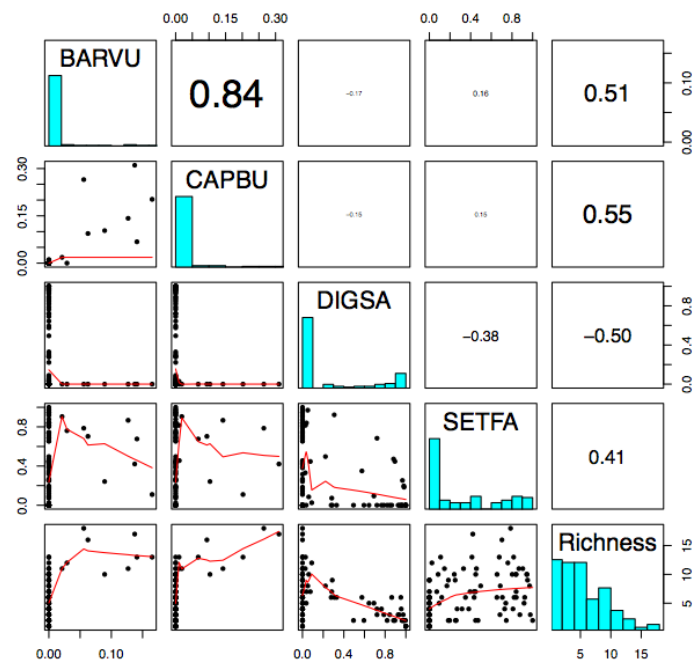


Figure S3. Pearson's correlation coefficients of the weed community diversity indices for a) soyabean (*GlycL*) and b) maize (*ZeaL*).



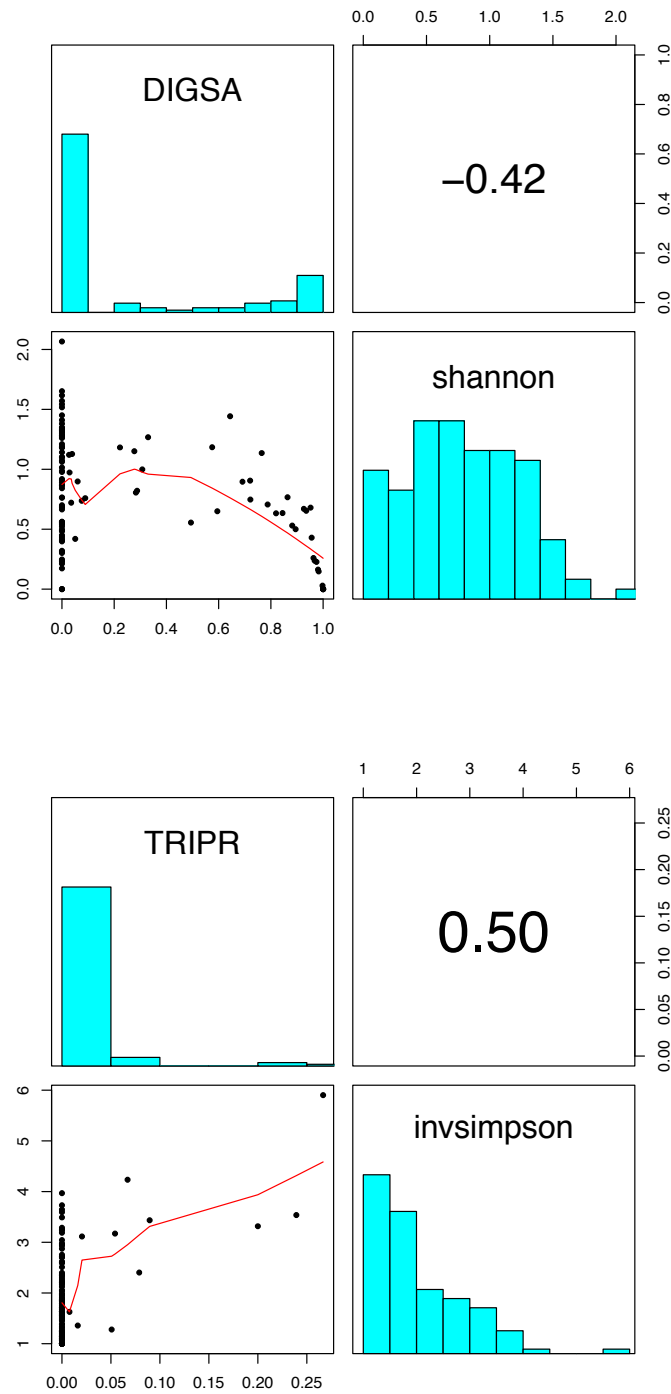


Figure S4. Correlations between weed diversity indices (E-evenness, richness, Shannon, inverse Simpson) and the Hellinger-transformed weed species data (biomass) soyabean (*GlycL*). We used a threshold of $|r| > 0.4$ for the correlations of interest. Large crabgrass (*Digitaria sanguinalis* L., DIGSA), red clover (*Trifolium pratense* L., ‘Michigan Mammoth Red’, TRIPR), garden yellowrocket (*Barbarea vulgaris* R. Br., BARVU), shepherd's purse (*Capsella bursa-pastoris* L., CAPBU), and giant foxtail biomass (*Setaria faberi* L., SETFA).

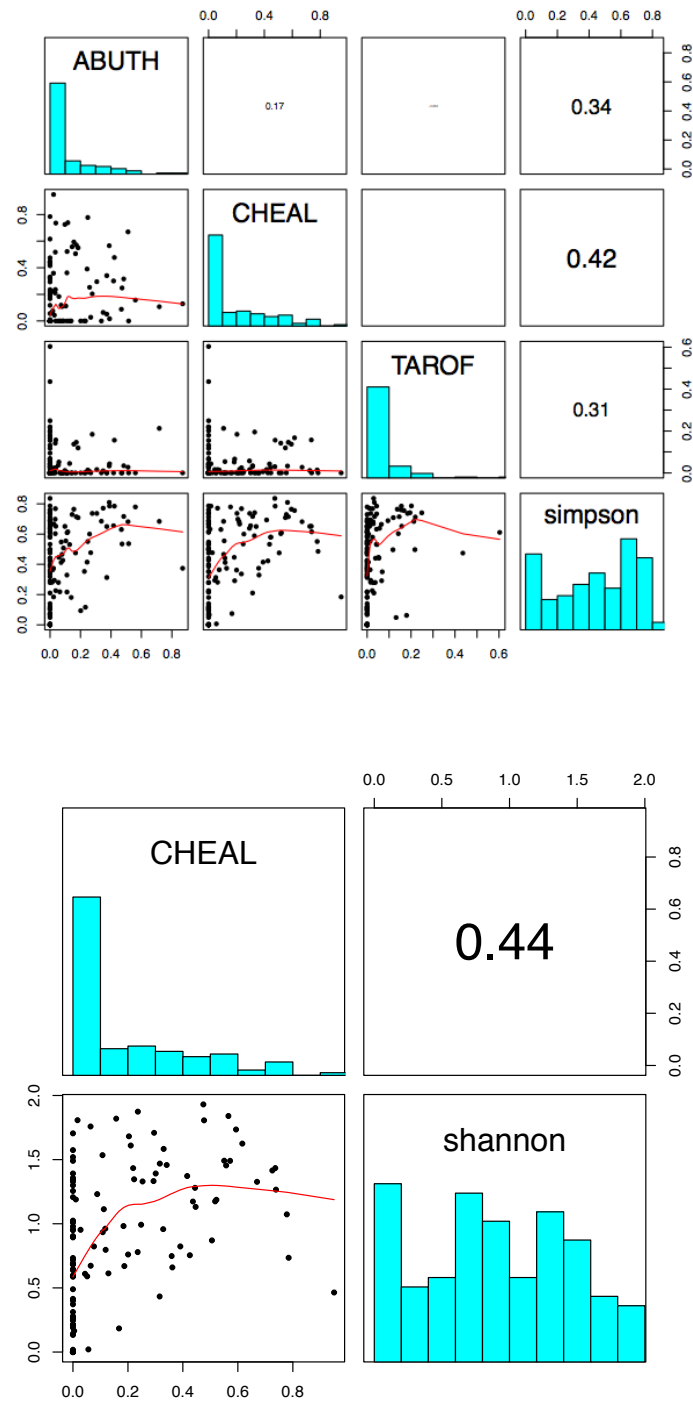


Figure S5. Correlations between weed diversity indices (Shannon and Simpson) and the Hellinger-transformed weed species data (biomass) for maize (*ZeaL*). We used a threshold of $|r| > 0.4$ for the correlations of interest. Lambsquarters (*Chenopodium album* L., CHEAL), common dandelion (*Taraxacum officinale*, TAROF) and velvetleaf (*Abutilon theophrasti* Medik, ABUTH).

Appendix A1. We used the *diversity* function in the **BiodiversityR** package of R-Software to estimate diversity in each crop system with the estimated weed biomass. We calculated the

species richness (S), Shannon–Wiener diversity index ($H = \sum_i p_i \ln(p_i)$), where p_i is the proportional biomass of species i and \ln is the natural logarithm), both variants of Simpson's index (based on $D = \sum_i p_i^2$, Simpson index $1 - D$ and Invsimpson index $1 / D$), J-evenness ($H / \ln(S)$) and E-evenness ($\exp(H) / S$),

Appendix A2. External perturbations (by climate or weed diversity) could translate the conditional function curve ($R_t = f(Y_{t-d}, Z)$) of maize and soybean yield with dynamic consequences. We modeled these effects by changes in each parameter of the equation (1). Changes in r_{\max} (I) and c (II) translate the curve moving it vertically and laterally, respectively, but do not influence its relative shape. However, perturbations in a (III) influence the relative shape of the conditional production curve. Perturbations in the parameters r_{\max} and a cause changes in the pattern of oscillation around equilibrium (its yield potential), but c perturbations do not. The stability of the equilibrium point is determined by the slope of the function in the vicinity of equilibrium ($r_{\max} * a$): the steeper the slope, the less stable the equilibrium.

